

1. REGRESYONUN (BAĞLAŞIMIN) TEMELLERİ

1.1. Regresyon ve Koşullu Beklenti Fonksiyonu. Varsayalım y_t gerçek bir tepki (response) değişkeni ve w_t birlikte değişkenlerin (covariates) bir d -vektörü olsun. Burada ilgilendiğimiz, y_t 'nin w_t verildiğindeki koşullu ortalamasıdır (beklentisidir):

$$g(w_t) := E[y_t | w_t].$$

Alışlageldiği üzere, bir regresyon denklemini de şu şekilde tanımlayabiliriz:

$$y_t = g(w_t) + \varepsilon_t, \quad E[\varepsilon_t | w_t] = 0,$$

burada y_t bir bağımlı değişken olarak, w_t bağımsız değişkenler olarak ve ε_t bozukluklar olarak düşünülmektedir.

Regresyon fonksiyonu, kayıpların karesi değerlendirilerek en iyi koşullu öndeyi (conditional prediction) probleminin çözümü olarak da tanımlanabilir: her bir w için şunu elde edebiliriz

$$g(w) = \arg \min_{\tilde{g} \in \mathbb{R}} E[(y_t - \tilde{g})^2 | w].$$

Böyle olunca, koşullu ortalama fonksiyonu koşulsuz öndeyi (unconditional prediction) problemini de çözmektedir:

$$g(\cdot) = \arg \min_{\tilde{g}(\cdot) \in \mathcal{G}} E[(y_t - \tilde{g}(w_t))^2],$$

burada argmin, w 'nin ölçülebilir tüm fonksiyonlarının sınıfı olan \mathcal{G} üzerinden hesaplanmaktadır. Bu düzenleme ne tahmine ne de hesaplamaya kolaylıkla çevrilebilmektedir.

Neticede, bu derste öğreneceklerimiz şunlardır

- önce, $g(w_t)$ 'nin $\beta \in \mathbb{R}^K$ ve orijinal bağlaştıranın (regressor) dönüşümleri olan x_t için $x_t' \beta$ ile yaklaştırması,

$$x_t = f(w_t),$$

burada dönüşümün seçimleri olan f yaklaştırım (approximation) teorisine bağlı olarak ifade edilmektedir,


¹Dersin orijinal notlarındaki dipnot: Bu notlar taslak halindedir. Hata bulduğunuzda lütfen bana e-mail ile haber veriniz (vchern@mit.edu).

- sonra, veriyi mümkün olduğu kadar iyi kullanarak $x'_t\beta'$ yı tahmin etmek ve $x'_t\beta$ ve ilgili miktarlar hakkında küçük-örneklem ve büyük-örneklemelere yönelik çıkarımlarda bulunmak.

Örnek 1: Engel (1857) çalışmasında, y_t hanehalkının gıda harcaması ve w_t hanehalkı geliri olarak verilmiştir. İyi bir yaklaştırma olarak şöyle bir kuvvet serisi kullanılabilir: $g(w_t) = \beta_0 + \beta_1 w_t + \beta_2 w_t^2$. Engel aslında Haar serilerini kullanmıştır (yaklaştırma birçok kukla terim kullanılarak yapılmıştır). Özellikle ilgimizi çeken, gelirin gıda tüketimi üzerindeki etkisidir

$$\frac{\partial g(w)}{\partial w}$$

Gıda Harcaması



ŞEKİL 1

Örnek 2: Varsayalım, y_t^* doğumdaki ağırlık ve w_t sigara içme ya da tıbbi bakımın kalitesi olsun. Açıktır ki, $E[y_t^*|w_t]$ ilgi çekici bir hedefdir. Varsayalım, w_t 'nin çok düşük doğum ağırlıkları üzerindeki etkisiyle ilgilenelim; bunu yapmanın bir yolu olarak şunu tanımlayabiliriz

$$y_t := 1\{y_t^* < c\},$$

burada c doğum ağırlığının kritik bir seviyesidir. Sonrasında şunu inceleyebiliriz

$$g(w_t) = E[y_t|w_t] = P[y_t^* < c|w_t].$$

Bu regresyon fonksiyonu uçdeğer (extreme) doğum ağırlığı gerçekleşmesi ihtimalinin birlikte değişkenlere bağlılığını ölçmektedir.²

Varsayalım $E[y_t|w_t]$ 'i elde edebildik. Bundan nasıl faydalanabiliriz?

Düşünce akımları:

1. Betimsel. İlginç biçimlendiren olguları (stylized facts) ortaya çıkarmak. Sigara içmek ortalama doğum ağırlığını "azaltır" (ancak uçdeğer doğum ağırlığının gerçekleşmesini azaltmaz).

2. İşlem Etkileri. Nedensel etkiler hakkında çıkarsamada bulunmak için ideal bir durum tam kontrol edilen rastsal deneme olarak düşünülür. Tam kontrol edilen rastsal deneme mevcut değilse, doğal deneyler de aranabilir.

3. Yapısal Etkiler. Ekonomik (nedensel, yapısal) bir modelin parametrelerini tahmin edelim. Ekonomi bilgisini kullanarak $E[y_t|x_t]$ 'nin neden ekonomik parametreleri özdeşleştirebileceğini ispat edelim. Varian'ın ilgili bölümüne bakınız.

1.2. Kitlede ve Sonlu Örneklemde OLS (sıradan en küçük kareler, Ordinary Least Squares).

1.2.1. *EDÖ (en iyi doğrusal öndeyici) Özelliği.* Kitlede en küçük karelerin β 'sı aşağıdaki terimin enküçültücüsüdür (argmin)

$$Q(b) = E[y_t - x_t'b]^2,$$

dolayısıyla $x_t'\beta$, y_t 'nin kitlede kare kayıp altında en iyi doğrusal öndeyicisidir. Sonlu örneklemde en küçük karelerin $\hat{\beta}$ 'i aşağıdaki terimin en küçültücüsüdür

$$Q_n(\beta) = E_n[y_t - x_t'\beta]^2,$$

burada E_n görgül beklentidir ($\frac{1}{n} \sum_{t=1}^n$ 'in kısaltması). Yani, $x_t'\hat{\beta}$, y_t 'nin örneklemde kare kayıp altında en iyi doğrusal öndeyicisidir.

β için sarıh bir çözüm de belirtebiliriz. Dikkat ederseniz β , $E[x_t x_t']$ tam kerteli (full rank) olduğunda, şu birinci derece koşulu çözmektedir

$$E[x_t(y_t - x_t'\beta)] = 0, \text{ yani } \beta = E[x_t x_t']^{-1} E[x_t y_t],$$

²Diğer bir yöntem ise y_t^* 'in bölütlerine (quantile) w_t 'nin bir fonksiyonu olarak bakmaktır, bu da bölüt regresyonunun gerçekleştirdiğidir.

Örnekleme en küçük kareler, $E_n[x_t x_t']$ tam kerteli olduğunda, kitle beklemlerini (moments) görgül beklemler ile değiştirmektedir:

$$E_n[x_t(y_t - x_t' \hat{\beta})] = 0, \text{ yani } \hat{\beta} = E_n[x_t x_t']^{-1} E_n[x_t y_t].$$

1.2.2. *En İyi Doğrusal Yaklaştırma olarak OLS.* Şunu gözlemleyebiliriz

$$Q(b) = E[y_t - x_t' b]^2 = E[E[y_t | w_t] - x_t' b + \varepsilon_t]^2 = E[E[y_t | w_t] - x_t' b]^2 + E[\varepsilon_t]^2,$$

burada $\varepsilon_t = y_t - E[y_t | w_t]$ 'dir. Yani β şunu çözmektedir

$$\min_b E(E[y_t | w_t] - x_t' b)^2,$$

ve $x_t' \beta$, koşullu ortalama fonksiyonu $E[y_t | w_t]$ için en iyi doğrusal yaklaşımdır. Bu da yaklaşıklık teorisine bir bağlantı oluşturmaktadır.

1.2.3. *İşlevsel Biçimleri (Functional Form) Oluşturmak.* Yaklaşıklık teorisine verilecek bağlantı, yaklaşıklık teorisinin regresyonlarımız için iyi işlevsel (fonksiyonel) biçimler oluşturmada kullanılabilmesi açısından faydalıdır. Burada, yaklaşıklık tasarımlarından ekonometrik uygulamalarda en çok yararlı olacaklar üzerine odaklanacağız.³

1. Kama (Spline) Yaklaşıklığı: Varsayalım w tek bağlaştıran olsun. Sonrasında doğrusal kama (1'inci dereceden kama), sonlu sayıda eşit mesafeli bağlantılar (knots) olan k_1, k_2, \dots, k_r ile şu şekilde ifade edilebilir:

$$x_t = f(w_t) = (1, w_t, (w_t - k_1)_+, \dots, (w_t - k_r)_+)'$$

burada $(u)_+$ terimi $u \times 1(u > 0)$ 'ı ifade eder. Kübik kama şu şekilde ifade edilebilir:

$$x_t = f(w_t) = (1, (w_t, w_t^2, w_t^3), (w_t - k_1)_+^3, \dots, (w_t - k_r)_+^3)'.$$

Kamaları tanımlarken x_t 'nin boyutu olan K' yi kontrol edebiliriz. Kamalar kullanılarak oluşturulan fonksiyon $w \mapsto f(w)'b$ 'nın, herhangi b için, w 'da iki kez türevi alınabilir.

2. Güç (Power) Yaklaşıklığı: Varsayalım w tek bağlaştıran (regressor) olsun ve $[0, 1]$ 'de dönüştürülmüş olsun; sonrasında, r -inci dereceden çokterimli serileri şu şekilde ifade edilebilir:

$$x_t = f(w_t) = (1, w_t, \dots, w_t^r)'.$$

Chebyshev çokterimlileri çoğu kez basit çokterimliler yerine kullanılmaktadır. Varsayalım $w_t \in [-1, 1]$ arasında değerler alacak şekilde dönüştürülmüş olsun. Chebyshev çokterimlileri

³W. Newey'in çalışması tahmin açısından faydalı bir uygulama sunmaktadır. Yaklaşıklık yöntemlerine faydalı bir başlangıç için K. Judd'm kitabına bakınız.

şu şekilde oluşturulabilir

$$x_t = f(w_t) = (\cos(j \cdot \cos^{-1}(w_t)), j = 0, \dots, r)$$

(Bunlara çokterimli denme sebebi şudur: $f(w_t) = (1, w_t, 2w_t^2 - 1, 4w_t^3 - 3w_t, \dots)$, ve böylece aslında w_t de çokterimlidir.)⁴

3. Dalgacık (Wavelet) Yaklaşıklığı: Varsayalım w tek bağlaştıran olsun ve $[0, 1]$ 'de dönüştürülmüş olsun; sonrasında, r -inci dereceden dalgacık serisi şu şekilde ifade edilebilir:

$$x_t = f(w_t) = (e^{j(i2\pi w_t)}, j = 0, \dots, r),$$

veya sinüs ve kosinüs tabanları ayrı ayrı kullanılabilir.

Çoklu bağlaştıranların olduğu durum da benzer şekilde incelenebilir: Varsayalım temel (basic) bağlaştıranlar şunlar olsun w_{1t}, \dots, w_{dt} , sonrasında her bir temel bağlaştıran için d serileri oluşturulabilir. Sonrasında d serilerinin tüm etkileşimleri, bunlara geren (tensor) çarpımları denir, oluşturulabilir ve bunların hepsi bağlaştıran vektörü x_t içinde toplanabilir. Eğer temel bir bağlaştıran için herbir seri J terime sahipse, sonuç (final) regresyonu $K \approx J^d$ boyutundadır, bu da d boyutunda üstel olarak patlamaktadır (boyutsallık belasının (curse of dimensionality) tezahürü). Geren çarpımlarının düzgün bir tanımı için bkz. Newey.

Teorem 1.1. *Varsayalım w_t 'nin \mathbb{R}^d 'de tanımlı bir küpte sınırlı bir desteği (bounded support) ve pozitif, sınırlı bir yoğunluğu olsun. Eğer $g(w)$ 'nin sınırlı türevlerle (sabit bir M ile) s -kere sürekli türevselliği varsa, yukarıda belirtilen şekilde K -terimli $x = f(w)$ serileri kullanılarak, yaklaşıklık hatası şu şekilde kontrol edilebilir:*

$$\min_b [E[g(w_t) - x_t' b]^2]^{1/2} \leq \text{const}_M \cdot K^{-\gamma/d},$$

burada kuvvet serileri ve dalgacıklar için $\gamma = s$ ve kamalar için $\gamma = \min(s, r)$ kullanılmıştır, r ise kamaların derecesidir.

Sonuçta, $K \rightarrow \infty$ iken, yaklaşıklık hatası sifira yakınsamaktadır. Teorem aynı zamanda düzgün (smooth) bir fonksiyonun yaklaşımının daha kolay olduğunu ve birçok temel bağlaştıranlı bir fonksiyonun yaklaşımının daha zor olduğunu söylemektedir (boyutsallık belasının başka bir tezahürü). Dikkat çeken başka bir husus da, $K \rightarrow \infty$ iken, yaklaşıklık hatası sifira yakınsamaktadır ifadesinin

⁴Daha fazla detay için K. Judd'ın kitabına bakınız; ayrıca şuraya da bakabilirsiniz <http://mathworld.wolfram.com/>

düzgünlük (smoothness) varsayımları olmadan dahi geçerli olduğudur; aslında $g(w)$ 'nin ölçülebilir olması ve kare (square) tümlevlenebilirliği (integrable) yeterlidir.


En küçük kareler kullanılarak fonksiyonların yaklaşıklığında kamaların ve Chebyshev serilerinin kullanımının olumlu özellikleri vardır, bu sadece ortalama kare yaklaşıklık hatasını enküçük yapmak için değil, aynı zamanda yaklaşılan terime (approximand) ençok mesafeyi elde etmede de geçerlidir (son özelliğe ortak-enküçüklük denmektedir (co-minimality)).

1.3. Yaklaşıklık Örnekleri. Örnek 1. (Yapay, synthetic) Varsayalım şu fonksiyon verilmiş olsun $g(w) = w + 2\sin(w)$, ve w_t tekdüze (uniform) şekilde şu tamsayılar üzerinde dağılmış olsun $\{1, \dots, 20\}$. Bu durumda OLS kitlede şu yaklaşıklık problemini çözer:

$$\beta = \arg \min_b E[g(w_t) - x_t'b]^2$$

burada $x_t = f(w_t)$ 'dir. Şimdi f için farklı işlevsel biçimleri deneyelim. Bu örnekte, $f(w)$ 'yi şu şekilde oluşturuyoruz (a) doğrusal kama (Şekil 2,sol) ve (b) Chebyshev serileri (Şekil 2,sağ), bu durumda $f(w)$ 'nin boyutları ya 3 ya da 8'dir.

Doğrusal kama ile yaklaştırma, $K=3$ ve 8 Chebyshev serileri ile yaklaştırma, $K=3$ ve 8



ŞEKİL 2

Sonrasında ise $g(w)$ fonksiyonunu grafik yardımıyla doğrusal yaklaşıklık $f(w)'\beta$ ile karşılaştıralım. Şekil 2'de $K = 3$ olan tutumlu (parsimonious) modelin küresel şekli (global shape) koşullu beklenti fonksiyonunda doğru olarak yaklaştırdığımız ("büyük değişiklikler"), ancak yerel şekli doğru olarak yaklaştıramadığımız ("küçük değişiklikler") görüyoruz. Daha esnek işlevsel biçimler $K = 8$ parametreleri ile kullanıldığında, yerel şekil için daha iyi bir yaklaşıklık elde ediliyor. Bu örnekte kamaların Chebyshev çokterimlilerinden çok daha iyi performans gösterdiklerini görüyoruz.

Yaklaşıklık hatasının düzgün ölçümlerine de bakabiliriz, mesela kök ortalama kare yaklaşıklık hatası gibi (KOKYH, root mean square approximation error, RMSAE):

$$[E[g(w_t) - f(w_t)'\beta]^2]^{1/2},$$

ve ençok yaklaşıklık hatası (EYH, maximum approximation error, MAE):

$$\max_w |g(w) - f(w)' \beta|.$$

Bu ölçüler aşağıdaki tabloda hesaplanmıştır:

	kama $K = 3$	kama $K = 8$	Chebyshev $K = 3$	Chebyshev $K = 8$
KOKYH	1.37	0.65	1.39	1.09
EYH	2.27	0.95	2.19	1.81


Örnek 2.(Reel) Burada $g(w)$ ücretin (y) logaritmasının ortalamasıdır ve eğitim üzerine koşulludur

$$w \in \{8, 9, 10, 11, 12, 13, 14, 16, 17, 18, 19, 20\}.$$


$g(w)$ fonksiyonu kitle verisi kullanılarak hesaplanmıştır – kullanılan veriseti ABD 1990 Nüfus Sayımı'ndaki yetişkin erkeklerdir ⁵. Burada bu fonksiyonun bağlaştıranlarını oluşturmak için yaygın yaklaştırma yöntemleri kullanıldığında, OLS tarafından ne kadar iyi yaklaştırıldığını bulmak istiyoruz. Problemi basitleştirmek için, w_t 'nin tekdüze olarak dağıldığını varsayabiliriz (diğer durumda sıklık (frequency) ile ağırlıklandırabiliriz) Kitlede, OLS şu yaklaştırma problemini çözmektedir: $\min E[g(w_t) - x_t'b]^2$ burada $x_t = f(w_t)$ 'dir ve $f(w)$ şu şekilde oluşturulur (a) doğrusal kama (Şekil 3,sol) ve (b) Chebyshev serileri (Şekil 3,sağ), bu durumda $f(w)$ 'nin boyutları ya $K = 3$ ya da $K = 8$ 'dir.

⁵Daha fazla detay için bkz. Angrist, Chernozhukov, Fernandez-Val, 2006, Econometrica, çalışması.

Doğrusal kama ile yaklaştırma, $K=3$ ve 8



Chebyshev serileri ile yaklaştırma, $K=3$ ve 8



ŞEKİL 3

Sonrasında, grafiksel olarak $g(w)$ fonksiyonunu $f(w)^\beta$ doğrusal yaklaştırması ile karşılaştırıyoruz. Aynı zamanda KOKYH ve EYH'yi kaydediyoruz. Yaklaştırma hataları aşağıdaki tabloda verilmiştir:

	kama $K = 3$	kama $K = 8$	Chebyshev $K = 3$	Chebyshev $K = 8$
KOKYH	0.12	0.08	0.12	0.05
EYH	0.29	0.17	0.30	0.12

REFERANSLAR:

1. Newey, Whitney K. Convergence rates and asymptotic normality for series estimators. *J. Econometrics* 79 (1997), no. 1, 147–168. (Regresyon kamalarının tanımları bu referansı takip etmektedir).
2. Judd, Kenneth L. *Numerical Methods in Economics*. MIT Press, Cambridge, MA, 1998. (Bölüm: Approximation Methods. Bu oldukça ileri seviye bir referanstır, ancak birçok ekonometrik ve ekonometrik olmayan uygulama için faydalıdır.)
3. Hal R. Varian. *Microeconomic Analysis* (Bölüm: Econometrics. Bu kitap Yapısal Ekonometri (Structural Econometrics) hakkında çok iyi bir okumadır ve içinde birçok ilginç fikir mevcuttur).

Bahsedilen materyaller şu adrese eklenmiştir: stellar.mit.edu.

2. REGRESYON CEBİRİ (REGRESSION CALCULUS)

2.1. Matris (Dizey, Matrix) Hesaplamaları. Aşağıdaki hesaplamalar sonlu örneklem çıkarımları için faydalıdır. $Y = (y_1, \dots, y_n)'$ olsun ve X de $n \times K$ boyutlu bir matris olsun: bu matrisin satırları şunlardır x'_t , $t = 1, \dots, n$. Bu gösterim ile şu ifadeyi yazabiliriz

$$\hat{\beta} = \arg \min_{b \in \mathbb{R}^k} (Y - Xb)'(Y - Xb),$$

Eğer $\text{kerte}(X) = K$ ise, yukarıdaki ifadenin Hessian'ı olan $2X'X$ pozitif tanımlıdır; bu da katı dışbükeyliği sağlar ve çözümün tekil (unique) olduğunu ifade eder. $\hat{\beta}$ 'nin çözümü normal denklemler (normal equations) denen birinci derece koşulları (first-order conditions, foc) tarafından belirlenir:

$$(1) \quad X'(Y - X\beta) = 0.$$

Bu denklemler çözüldüğünde şu ifade elde edilir

$$\hat{\beta} = (X'X)^{-1}X'Y.$$

Uyumlu (fitted) veya öndeyilen (predicted) değerler şu vektörler (yöney, vector) ile ifade edilir

$$\hat{Y} := X\hat{\beta} = X(X'X)^{-1}X'Y = P_X Y,$$

Kalıntılar (residual) da şu şekilde tanımlanır:

$$\hat{e} := Y - X'\hat{\beta} = (I - P_X)Y = M_X Y.$$

Geometrik yorumlama: $L := \text{yayımla (span)}(X) := \{Xb : b \in \mathbb{R}^k\}$ X 'in sütunları tarafından yayılan doğrusal uzay (linear space) olsun. P_X matrisi izdüşüm matrisi (projection matrix) olarak adlandırılır, çünkü Y 'nin L üzerine izdüşümünü verir. M_X matrisi ise Y 'nin L 'ye dikeysel (orthogonal) olan alt uzay (subspace) üzerine olan izdüşümünü veren izdüşüm matrisidir.

Aslında, LS (en küçük kareler tahmincisi) şu problemi çözer:

$$\min_{Y^* \in L} (Y - Y^*)'(Y - Y^*)$$

Çözüm olan $Y^* = \hat{Y}$ ise Y 'nin L üzerine olan dikeysel izdüşümüdür, yani

$$(i) \hat{Y} \in L \quad (ii) S'\hat{e} = 0, \forall S \in L, \hat{e} := (Y - \hat{Y}) = M_X Y.$$

Bunu gözümüzde canlandırmak için şöyle bir basit örnek kullanalım: $n = 2$, tek boyutlu bağıştıran olsun ve kesme (intercept) olmasın, yani şunlar geçerli olsun $Y = (y_1, y_2)' \in \mathbb{R}^2$, $X = (x_1, x_2)' \in \mathbb{R}^2$ ve $\beta \in \mathbb{R}$.

Dikkat etmemiz gereken bazı özellikler şunlardır:

1. Eğer regresyonda kesme varsa, yani X 'in bir sütunu şu ise $\mathbf{1} = (1, \dots, 1)'$, bu takdirde $\bar{Y} = \bar{X}'\hat{\beta}$ 'dir. Regresyon doğrusu verinin ortalamalarının içinden geçmektedir. Buna eşdeğer olarak, $\mathbf{1} \in L$ olduğu için, $\mathbf{1}'\hat{e} = 0$ veya $\bar{\hat{e}} = 0$ 'dir.

2. İzdüşüm ("şapka" (hat)) matrisi $P_X = X(X'X)^{-1}X'$ simetriktir ($P_X' = P_X$) ve denggüçlüdür (idempotent) ($P_X P_X = P_X$). P_X bir dikey izdüşüm işlemcisidir ve \mathbb{R}^n 'deki vektörleri L ile eşleştirir (mapping). Özellikle, $P_X X = X$, $P_X \hat{e} = \mathbf{0}$, $P_X Y = X\hat{\beta}$ 'dir.

3. İzdüşüm matrisi $M_X = I - P_X$ de simetrik ve denggüçlüdür. M_X ise \mathbb{R}^n 'deki vektörleri L 'ye dikey olan doğrusal uzayla eşleştirir. Özellikle, $M_X Y = \hat{e}$, $M_X X = \mathbf{0}$, ve $M_X \hat{e} = \hat{e}$ 'dir. Ayrıca dikkat ediniz, $M_X P_X = \mathbf{0}$ 'dir.

2.2. Bölüntülü (Partitioned) veya Kısmi (Partial) Regresyon. X_1 ve X_2 , X 'i şu şekilde bölüntülesinler

$$X = [X_1, X_2]$$

ve sonra bir regresyon modeli düşünelim

$$Y = X_1\beta_1 + X_2\beta_2 + \varepsilon.$$

Daha sonra ise, $P_{X_2} = X_2(X_2'X_2)^{-1}X_2'$ ve $M_{X_2} = I - P_{X_2}$ olsun. Ek olarak, $\hat{V}_1 = M_{X_2}X_1$ ve $\hat{U} = M_{X_2}Y$ olsun, yani X_1 'in sütunlarının X_2 üzerine olan regresyonundan \hat{V}_1 kalıntı matrisi olarak elde edilsin ve Y 'nin X_2 üzerine olan regresyonundan \hat{U} kalıntı matrisi olarak elde edilsin.

Teorem 2.1. *Şu tahminciler eşdeğerlidir: 1. Y 'nin X_1 ve X_2 üzerine regresyonundan elde edilen $(\hat{\beta}'_1, \hat{\beta}'_2)'$ vektörler tahminininin $\hat{\beta}_1$ bileşeni, 2. Y 'nin \hat{V}_1 üzerine regresyonundan elde edilen $\tilde{\beta}_1$, 3. \hat{U} 'in \hat{V}_1 üzerine regresyonundan elde edilen $\bar{\beta}_1$.*

İspat. Yukarıda denklem (1) de gösterilen olguyu hatırlayalım:

(2) $\hat{\gamma}$, ancak ve ancak $Z'(Y - Z\hat{\gamma}) = 0$ ise, Y 'nin Z üzerindeki OLS'idir.

Şunu yazalım

$$Y = X_1\hat{\beta}_1 + X_2\hat{\beta}_2 + \hat{e} = \hat{V}_1\hat{\beta}_1 + \underbrace{(X_1 - \hat{V}_1)\hat{\beta}_1 + X_2\hat{\beta}_2 + \hat{e}}_{\hat{\eta}}$$

Yukarıdaki olgu (2) kullanılarak $\hat{\beta}_1 = \bar{\beta}_1$ eşitliği ancak ve ancak $\hat{V}_1' \hat{\eta} = 0$ ise gerçekleşir. Son çıkarsama şuradan gelir: $\hat{V}_1 = M_{X_2} X_1 \in \text{yayımla}(X)$ 'den dolayı $\hat{V}_1' \hat{e} = 0$, $X_2' \hat{V}_1 = X_2' M_{X_2} X_1 = 0$ ve $(X_1 - \hat{V}_1)' \hat{V}_1 = (P_{X_2} X_1)' M_{X_2} X_1 = 0$.

$\hat{\beta}_1 = \bar{\beta}_1$ eşitliğini göstermek için, şöyle yazalım

$$M_{X_2} Y = M_{X_2} (X_1 \hat{\beta}_1 + X_2 \hat{\beta}_2 + \hat{e}),$$

bu da eşdeğer olarak şu şekilde belirtilebilir ($M_{X_2} X_2 = 0$ olduğuna dikkat ediniz)

$$\hat{U} = \hat{V}_1 \hat{\beta}_1 + M_{X_2} \hat{e}.$$

$\hat{V}_1' M_{X_2} \hat{e} = (M_{X_2} X_1)' (M_{X_2} \hat{e}) = X_1' M_{X_2} \hat{e} = \hat{V}_1' \hat{e} = 0$ olduğu için, şu sonuç elde edilir $\hat{\beta}_1 = \bar{\beta}_1$.

Kısmi Regresyonun Uygulamaları:

1. Yorum: $\hat{\beta}_1$ bir *kısmi* regresyon katsayısıdır.

2. Ortalamadan Fark Alma (De-meaning): Eğer $X_2 = \mathbf{1}$ ise, bu taktirde $M_{X_2} = I - \mathbf{1}(\mathbf{1}'\mathbf{1})^{-1}\mathbf{1}' = I - \mathbf{1}\mathbf{1}'/n$ ve $M_{X_2}Y = Y - \mathbf{1}\bar{Y}$, $M_{X_2}X_1 = X_1 - \mathbf{1}\bar{X}_1$ 'dir. Bu sebeple, Y 'nin bir sabit $X_2 = \mathbf{1}$ ve diğer bağıştıranların bir kümesi olan X_1 üzerine regresyonu şu şekilde elde edilenlerle aynı eğim katsayılarını verir: (1) Y 'nin kendi ortalamasından sapmasının X_1 'in kendi ortalamasından sapması üzerine regresyonu, veya (2) Y 'nin X_1 'in kendi ortalamasından olan sapması üzerine regresyonu.

3. Ayrı Regresyonlar: Eğer X_1 ve X_2 dikeysel ise, yani $X_1'X_2 = 0$, sonrasında Y 'nin X_1 ve X_2 üzerine regresyonundan elde edilen $\hat{\beta}_1$, Y 'nin X_1 üzerine regresyonundan elde edilen $\tilde{\beta}_1$ 'e eşdeğerdır. Bunu göstermek için şöyle yazalım $Y = X_1\hat{\beta}_1 + (X_2\hat{\beta}_2 + \hat{e})$ ve, dikkat ediniz, $X_1'X_2 = 0$ ve $X_1'\hat{e} = 0$ kullanılarak $X_1'(X_2\hat{\beta}_2 + \hat{e}) = 0$ 'dır. Olgu (2) kullanılarak, $\hat{\beta}_2 = \tilde{\beta}_2$ elde edilir.

4. Dışlanmış Değişken Yanlılığı (Omitted Variable Bias): Eğer X_1 ve X_2 dikeysel değil ise, yani $X_1'X_2 \neq 0$, sonrasında Y 'nin X_1 ve X_2 üzerine regresyonundan elde edilen $\hat{\beta}_1$, Y 'nin X_1 üzerine regresyonundan elde edilen $\tilde{\beta}_1$ 'e eşdeğer değildir. Ancak, şunu gösterebiliriz

$$\tilde{\beta}_1 = (X_1'X_1)^{-1}X_1'(X_1\hat{\beta}_1 + X_2\hat{\beta}_2 + \hat{e}) = \hat{\beta}_1 + (X_1'X_1)^{-1}X_1'(X_2\hat{\beta}_2).$$

Yani, "kısa" regresyondaki katsayı, "uzun" regresyondaki katsayı artı "dışlanmış" terim olan $X_2\hat{\beta}_2$ 'nin regresyona dahil olan X_1 bağıştıranı üzerine yapılan regresyonundan elde edilen katsayıya eşittir. Buradaki ilişkinin kitle için de kolaylıkla kullanılabileceğini görebiliriz.

Örnek: Varsayalım Y kazanç, X_1 eğitim ve X_2 gözlemlenemeyen yetenek olsun. "Uzun" katsayı $\hat{\beta}_1$ ile "kısa" katsayı $\tilde{\beta}_1$ 'i karşılaştıralım.

2.3. İzdüşümler (Projections), R^2 ve Varyans (Değişirlik) Çözümlemesi (ANOVA). Faydalı bir uygulama R^2 'nin türetimidir; bu kriter, Y 'deki değişimin ne kadarının X 'teki değişim ile açıklandığını gösterir. Orijinden geçen regresyonda, aşağıdaki varyans çözümlemesi ayrıştırmasını gösterebiliriz (analysis of variance,

ANOVA)

$$Y'Y = \hat{Y}'\hat{Y} + \tilde{e}'\tilde{e}.$$

Buradan $R^2 := \hat{Y}'\hat{Y}/Y'Y = 1 - \tilde{e}'\tilde{e}/Y'Y$ ve oluşum gereği $0 \leq R^2 \leq 1$.

Eğer regresyon kesme içeriyorsa, yukarıdaki değerlerin ortalamadan farkını almak mantıklıdır. Bu durumda formül şuna dönüşür

$$(Y - \bar{Y})'(Y - \bar{Y}) = (\hat{Y} - \bar{Y})'(\hat{Y} - \bar{Y}) + \tilde{e}'\tilde{e},$$

ve

$$R^2 := (\hat{Y} - \bar{Y})'(\hat{Y} - \bar{Y})/((Y - \bar{Y})'(Y - \bar{Y})) = 1 - \tilde{e}'\tilde{e}/(Y - \bar{Y})'(Y - \bar{Y}),$$

burada $0 \leq R^2 \leq 1$ 'dir ve kalıntılar tanım gereği, aşağıda gösterildiği gibi, sıfır ortalamasına sahiptir.

3. SONLU ÖRNEKLEMLERDE TAHMIN VE BASIT ÇIKARSAMA

3.1. Gauss-Markov (GM) Modelinde Tahmin ve Çıkarsama. GM modeli (Y, X) verisi için ihtimal yasalarının $\{P_\theta, \theta \in \Theta\}$ bir toplamıdır ve şu özelliklere sahiptir:

GM1	$Y = X\beta + \varepsilon,$	$\beta \in \mathbb{R}^k$	doğrusallık
GM2	$kerte(X) = k$		özdeşleştirme (identification)
GM3	$E_\theta[\varepsilon X] = 0$	$\forall \theta \in \Theta$	dikeysellik, doğru belirginleştirme (specification), dışsallık (exogeneity)
GM4	$E_\theta[\varepsilon\varepsilon' X] = \sigma^2 I_{n \times n}$	$\forall \theta \in \Theta$	küresellik (sphericity)

Burada, ihtimal modeli P_θ 'yı tanımlayan θ parametresi şunlardan oluşur

$$(\beta, \sigma^2, F_{\varepsilon|X}, F_X),$$

burada β regresyon parametre vektörü, σ^2 bozukluk varyansı (variance of disturbances), $F_{\varepsilon|X}$, ε hatalarının X verildiğinde koşullu dağılım fonksiyonu (conditional distribution function) ve F_X ise X 'in dağılım fonksiyonudur. Hem $F_{\varepsilon|X}$ hem de F_X belirginleştirilmemişlerdir (unspecified), yani parametrik değildirler (non-parametric).

Bu model hakiki (actual) verinin birçok gerçekçi özelliğini yok sayar, ancak analiz için faydalı bir başlangıç noktasıdır. Ayrıca, bu bölümün ilerki kısımlarında hatalarının dağılımını normal dağılım takip edecek şekilde kısıtlayacağız.

GM1 & GM3: Bu varsayımlar birlikte değerlendirilmelidir, ancak GM3'ten aşağıda daha detaylı bahsedilecektir. Model, parametrelerin ve hata teriminin doğrusal bir fonksiyonu olarak yazılabilir, yani $y_i = \beta'x_i + \varepsilon_i$, burada GM3 $E[\varepsilon_i|x_i] = 0$ olduğunu, ve, aşağıda da bahsedildiği gibi, aslında daha fazlasını da belirtir.

Burada ifade edilen, Y 'nin koşullu ortalama fonksiyonunu parametrelerde doğrusal olan bir işlevsel biçim ile doğru şekilde belirginleştirdiğimizdir. Bu noktada, işlevsel biçimleri yaklaştırma teorisi ile nasıl oluşturduğumuzu hatırlayabiliriz. Bahsedilen noktada, x_t 'yi bazı basit bağlaştıranlar olan $f(w_t)$ 'nin dönüşümleri (transformations) olarak oluşturmuştuk. Neticede, GM1 ve GM3 varsayımları şunu belirtecek şekilde yorumlanabilir: $E[y_t|w_t] = E[y_t|x_t] = x_t'\beta$, bu da bir tam (perfect) işlevsel biçimle ve yaklaştırma hatası nümerik olarak önemsemeye değermez olduğunda çalıştığımız

bir varsayımdır. Bir çok ekonomik işlevsel biçim belirtilen varsayımlar ile gayet iyi eşleşmektedir.⁶

GM2: Özdeşleştirme.⁷ Bu varsayım açıklayıcı değişkenlerin doğrusal olarak bağımsız olduklarını ifade etmektedir. Takip eden örnek bu koşulun arkasındaki düşüncenin altını çizmektedir. Varsayalım şu ücret denklemini tahmin etmek istiyorsunuz:

$$\log(\text{ücret}_i) = \beta_1 + \beta_2 \text{eğitim}_i + \beta_3 \text{süre}_i + \beta_4 \text{tecrübe}_i + \varepsilon_i$$

burada eğitim_i kaç yıl okul eğitimi alındığını, süre_i mevcut işte çalışılan süreyi ve tecrübe_i işgücündeki tecrübeyi (yani şu anki iş dahil olmak üzere tüm işlerde çalışılan toplam süreyi) göstermektedir.

Ancak örnekte hiç kimsenin işini değiştirmedeğini düşünelim, yani tüm i 'ler için $\text{süre}_i = \text{tecrübe}_i$ olsun. Bu eşitliği regresyon denkleminde yerine koyduğumuzda şunu görürüz:

$$\log(\text{ücret}_i) = \beta_1 + \beta_2 \text{eğitim}_i + (\beta_3 + \beta_4) \text{tecrübe}_i + \varepsilon_i.$$

Sonuçta $\beta_3 + \beta_4$ doğrusal kombinasyonunu tahmin edebilirken β_3 ve β_4 'ü ayrı ayrı tahmin edemeyiz. Bu olay *kısmi özdeşleştirme (partial identification)* olarak bilinir. Ekonometride bu durumla düşünüldüğünün tersine sıkça karşılaşılır.

GM3: Dikeysellik veya Katı Dışsallık (Strict Exogeneity). Burada, bozukluk teriminin beklenen değeri açıklayıcı değişkenlere bağlı değildir:

$$E[\varepsilon|X] = 0.$$

Dikkat ederseniz, bu sadece $E[\varepsilon_i|x_i] = 0$ olduğunu değil, aynı zamanda tüm j 'ler için $E[\varepsilon_i|x_j] = 0$ olduğunu ifade eder. Yani, i gözlemi için bozukluk teriminin beklenen değeri sadece o gözlemin açıklayıcı değişkenlerine değil, aynı zamanda diğer tüm gözlemlerin açıklayıcı değişkenlerine de bağlı değildir. Son ifade zaman serileri için mantıksız bir koşul olabilse de, bu koşulu bir sonraki bölümde kaldıracağız.

⁶Örneğin, Cobb-Douglas üretim fonksiyonu gibi doğrusal olmayan bir model $y_i = AK_i^\alpha L_i^{1-\alpha} e^{\varepsilon_i}$ logaritmalar alınarak kolaylıkla doğrusal bir modele dönüştürülebilir:

$$\ln y_i = \ln A + \alpha \ln K_i + (1 - \alpha) \ln L_i + \varepsilon_i$$

Bu aynı zamanda daha önce türettiğimiz çokterimli yaklaşımlara güzel bir bağlantı oluşturur. Aslında, yukarıdaki denkleme $(\ln L)^2$ ve $(\ln K)^2$ gibi ek terimler katıldığında bir translog işlevsel biçimi elde edilir ve bu da ikinci dereceden bir çokterimli yaklaşımdır. Açık ki, yaklaştırma teorisi ve ekonomik modelleme arasındaki bağlantıları keşfetmek için ilginç bir fırsat mevcuttur.

⁷Bu örnek ve aşağıdaki örneklerden bazıları Raymond Guiterras tarafından hazırlanmıştır.

Ek olarak, daha önce de vurgulandığı üzere, bu varsayım koşullu ortalama fonksiyonunda tam yaklaştırma (perfect approximation) olduğunu varsaydığı için de mantıksız olabilir.

Bu varsayımın neden dikkatle değerlendirilmesi gerektiğine yönelik başka bir sebep de vardır. Ekonometrik analizin esas amaçlarından birinin nedensel ya da yapısal etkileri ortaya çıkartmak olduğunu hatırlayınız. Eğer regresyonun nedensel bir yorumlaması olacaksa, doğru nedensel denklemin bozuklukları

$$y_i = x_i' \gamma + u_i$$

$E[u_i|x_i] = 0$ gibi dikeysellik kısıtlamalarını sağlamak zorundadır. Bu gerçekleşirse, sonrasında nedensel etki fonksiyonu $x_i' \gamma$ regresyon denklemi $x_i' \beta$ ile çıkarılacaktır.

Aşağıdaki standart örnek bu fikri netleştirmemizde yardımcı olacaktır. Gelir ve eğitim seviyesi ilişkisi ve gerçek model hakkındaki düşüncemiz şöyledir:

$$y_i = \gamma_1 x_i + u_i, \quad u_i = \gamma_2 A_i + \varepsilon_i$$

burada x_i eğitim seviyesi iken, u_i ise yetenek etkisi olan $\gamma_2 A_i$ 'den ve x_i , A_i ve ε 'den bağımsız olan ikinci bir kalıntı ε_i 'den oluşmaktadır. Varsayalım hem eğitimin hem de yeteneğin ortalamadan farkı alınsın, yani, x_i ortalama eğitimden sapmayı ölçsün ve A_i ortalama yetenekten sapma olsun. Genel olarak, eğitim ile yetenek alakalıdır, yani

$$E[u_i|x_i] = \gamma_2 E[A_i|x_i] \neq 0.$$

Bu nedenle, dikeysellik bozulmaktadır ve γ_1 'i y_i 'nin x_i üzerine regresyonu ile tahmin etmek mümkün değildir. Ancak dikkat ederseniz, eğer yetenek olan A_i 'yi gözlemleyebilirsek ve y_i 'nin eğitim x_i ve yetenek A_i üzerine uzun regresyonunu yapabilirsek, bu taktirde regresyon katsayıları olan β_1 ve β_2 vasıtasıyla nedensel fonksiyonun katsayıları olan γ_1 ve γ_2 hesaplanabilecekti.

GM4: Küresellik. Bu varsayım iki önemli gerekliliği içerir. Bunlardan birincisi *eşit yayılım'dır (homoscedasticity):* $E[\varepsilon_i^2|X] = \sigma^2, \quad \forall i$. Bunun manası, her bir bozukluk teriminin koşullu varyansının (conditional variance) tüm gözlemler için aynı olmasıdır. Bu genellikle gerçekçilikten oldukça uzak bir varsayımdır.

İkinci koşul ise *kendiyle ilgileşim olmaması'dır (nonautocorrelation):* $E[\varepsilon_i \varepsilon_j|X] = 0 \quad \forall i \neq j$. Bunun manası da herhangi iki farklı gözleme ait bozuklukların ilgileşimsiz (uncorrelated) olmasıdır. Zaman serisi verisinde bozukluklar çoğu kez kendiyle ilgileşimlidir.

Ek olarak, bu varsayım dolaylı olarak birçok ikili tepki modelini (binary response models) (ve diğer kesikli tepki (discrete response) modellerini) ortadan kaldırır. Örneğin, varsayalım $y_i \in \{0, 1\}$ olsun, bu durumda

$$y_i = E[y_i|x_i] + \varepsilon_i = Pr[y_i = 1|x_i] + \varepsilon_i,$$

burada ε_i 'nin varyansı $P[y_i = 1|x_i](1 - P[y_i = 1|x_i])$ 'dir ve bu da x_i 'ye bağlıdır; bunun istisnası ilgimizi çekmeyen $P[y_i = 1|x_i]$ durumudur, bu da x_i 'ye bağlı değildir.

3.2. Gauss-Markov Modelinde OLS'nin Özellikleri. İlgimizi çeken, β 'nin çeşitli işlevselleridir, örneğin,

- β_j , β 'nin ilgilenebileceğimiz bir j -inci bileşeni,
- $(x_1 - x_0)'\beta$, bağlaştıran değerlerindeki bir değişiklikten kaynaklanan koşullu ortalamanın bir kısmı farkı (partial difference),
- $\frac{\partial x(w)'}{\partial w_k} \beta$, koşullu ortalamanın temel (elementary) bağlaştıran w_k ile bir kısmı türevi.

Bu işlevseller şu biçim ile oluşur

$$c'\beta \text{ geçerli olduğu } c \in \mathbb{R}^K \text{ için.}$$

Bu durumda, $\hat{\beta}$ 'nin etkinliğini (efficiency) bu tür işlevselleri mümkün olabildiği kadar kesin (precise) tahmin etme yeteneği olarak tanımlamak mantıklıdır.

Belirtilen varsayımlar ile, şu durumlar elde edilir

$$E_\theta[\hat{\beta}|X] = E_\theta[(X'X)^{-1}X'(X\beta + \varepsilon) | X] = I\beta + 0 = \beta \quad \forall \theta \in \Theta.$$

Bu özellik ortalama-yansızlık (mean-unbiasedness) olarak adlandırılır. Bunun manası da, özellikle, doğrusal işlevsellerin tahminlerinin de yansız olduğudur $E_\theta[c'\hat{\beta}|X] = c'\beta$.

Şimdi, regresyon katsayısı β için OLS'nin etkinliğini diğer tahminciler ile karşılaştıralım. Rekabet edecek aday tahminci $\tilde{\beta}$ doğrusal ve yansız olsun. Doğrusallığın manası $\tilde{\beta} = a + AY$ olmasıdır, burada a ve A , X 'in ölçülebilir fonksiyonudur (measurable function) ve tüm Θ içindeki θ için $E_\theta[\tilde{\beta}|X] = \beta$ 'dir. Dikkat ederseniz, yansızlık koşulu tüm $\beta \in \mathbb{R}^k$ için $a + AX\beta = \beta$ olmasını gerektirir. Yani,

$$AX = I \text{ ve } a = 0 \text{ 'dır.}$$

Teorem 3.1. *Gauss-Markov Teoremi.* GM modelinde, X üzerine koşullu olarak, β 'nin en küçük varyans doğrusal yansız tahmincisi (EVDYT, minimum variance linear unbiased estimator, MVLUE) $\hat{\beta}$ 'dir; bunun manası da herhangi bir diğer doğrusal yansız tahminci $\tilde{\beta}$ 'nin şu ilişkiyi sağlayacağıdır:

$$\text{Var}_\theta[c'\tilde{\beta} | x] \geq \text{Var}_\theta[c'\hat{\beta} | X], \quad \forall c \in \mathbb{R}^K, \quad \forall \theta \in \Theta.$$

Yukarıdaki özellik şuna denktir: $c'\text{Var}_\theta[\tilde{\beta} | X]c - c'\text{Var}_\theta[\hat{\beta} | X]c \geq 0 \quad \forall c \in \mathbb{R}^K, \quad \forall \theta \in \Theta$, bu da şunu söylemekle aynıdır

$$\text{Var}_\theta[\tilde{\beta} | X] - \text{Var}_\theta[\hat{\beta} | X], \quad \forall \theta \in \Theta \text{ için pozitif tanımlıdır.}$$

Örnek. Varsayalım y_t kazançları, x_t alınan eğitim süresini temsil etsin. Eğitim süresindeki değişikliğin ortalama etkisi şudur $E[y_t | x_t = x^*] - E[y_t | x_t = x] = (x^* - x)'\beta$. GM Teoremi kullanılarak, $(x^* - x)'\beta$ için $(x^* - x)'\hat{\beta}$ EVDYT'dir.

Örnek. OLS'in bir rakibi WLS'dir (weighted least squares, ağırlıklı en küçük kareler) ve ağırlıkları $W = \text{diag}(w(x_1), \dots, w(x_n))$ 'dir. WLS şunu çözer: $\min_\beta E_n[(y_t - x_t'\beta)^2 w(x_t)]$, veya, denk olarak $\min_\beta (Y - X\beta)'W(Y - X\beta)$. Çözüm $\hat{\beta}_{WLS} = (X'WX)^{-1}X'WY$ 'dir ve $\hat{\beta}_{WLS}$ doğrusal ve yansızdır (bunu gösteriniz). GM1-GM4 varsayımları altında WLS, OLS ile çakışmadığı müddetçe, OLS'ten daha az etkindir.

3.3. GM Teorem'inin İspatı. Notasyonda, θ ile endekslemeden vazgeçelim. Yansızlığın sağlanması yukarıda yapılmıştı. Herhangi bir başka yansız tahminciyi ele alalım: $\tilde{\beta} = AY$. Yansızlık özelliği ile, $AX = I$ 'dir. Şu hususları gözlemleyebiliriz: $\text{var}[c'\tilde{\beta} | X] = c'AA'c\sigma^2$ ve $\text{var}[c'\hat{\beta} | X] = c'(X'X)^{-1}c \cdot \sigma^2$. Aşağıdaki eşitliği göstermemiz yeterlidir

$$\text{var}[c'\tilde{\beta} | X] - \text{var}[c'\hat{\beta} | X] = \text{var}[c'\tilde{\beta} - c'\hat{\beta} | X],$$

çünkü sağ taraf negatif değildir. Şunu yazalım

$$\begin{aligned} \text{var}[c'\tilde{\beta} - c'\hat{\beta} | X] &= \text{var}\left[\underbrace{c'(A - (X'X)^{-1}X')}_M (X\beta + \epsilon) | X\right] \\ &= \text{var}[M\epsilon | X] = E[M\epsilon\epsilon'M' | X] = MM'\sigma^2 \quad (\text{A4'ten dolayı}) \\ &= c'[AA' - (X'X)^{-1}]c \cdot \sigma^2 \quad (\Leftarrow AX = I) \\ &= c'AA'c\sigma^2 - c'(X'X)^{-1}c \cdot \sigma^2 \square \end{aligned}$$

Açıklama: Bu ispat, portföy teorisi ve Hausman-türü testler gibi birçok yerde kullanılan genel bir prensibi göstermektedir. Dikkat ederseniz, farkın varyansı, kovaryansı (eşdeğişirlik, covariance) gerektirmeyen çok basit bir yapıya sahiptir:

$$\text{var}[c'\tilde{\beta} - c'\hat{\beta} \mid X] = \text{var}[c'\tilde{\beta} \mid X] - \text{var}[c'\hat{\beta} \mid X]$$

Bunun sebebi şudur

$$\text{cov}[c'\tilde{\beta}, c'\hat{\beta} \mid X] = \text{var}[c'\hat{\beta} \mid X].$$

Bunun manası da etkinsiz tahmin (inefficient estimate) $c'\tilde{\beta}$ şuna eşittir: etkin bir tahmin olan $c'\hat{\beta}$ artı etkin tahmin ile ilgileşimsiz (uncorrelated) ek bir tahmin rastsalı (noise).

3.4. OLS'in Rakipleri ve Alternatifleri. Bölüm I. Şu örnekleri değerlendirelim.

Örnek [*Uzman (expert) Tahminlerine karşı OLS*] Bir uygulama olarak, varsayalım $\beta = (\beta_1, \dots, \beta_k)'$ olsun; burada β_1 bir ürünün talep elastikiyetini ölçer. Bahsettiğimiz tanımlar ve GM teoremi çerçevesinde, iki tahminciyi analiz edelim ve karşılaştıralım: sabit tahmin $\beta_1^* = 1$ bir endüstriyel organizasyon uzmanı tarafından sağlanmış olsun ve $\hat{\beta}_1$ sıradan enküçük kareler tahmini olarak elde edilsin.

- Hangi durumda bunlardan birini diğerine tercih edersiniz?
- GM teoremi bu karar ile alakalı mıdır?

Uzman tahmini, OLS'ten ortalama kare hata açısından daha iyi olabilir:

$$E_{\theta}[(\beta^* - \beta)^2] < E_{\theta}[(\hat{\beta} - \beta)^2]$$

bu bazı veya birçok $\theta \in \Theta$ değerleri için geçerlidir, bu da doğrusal işlevsellerin daha küçük tahmin hatası yaptığı manasına gelir. Kararın kritik yönü Θ 'nın değeri hakkında ne düşündüğümüzdür. Daha detaylı bilgi için Bölüm 3.9'a da bakınız.

Örnek [*Fire (shrinkage) Tahminlerine karşı OLS*] Fire tahmincileri öğrenme teorisinde yeniden gündeme gelmektedir, bu da regresyon çözümlemesi demenin modern bir yoludur.

Fire tahmincilerinin bir örneği, şu örneği çözendir:

$$\min_b [(Y - Xb)'(Y - Xb)/2 + \lambda(b - \beta^*)'X'X(b - \beta^*)]$$

İlk terime sadakat/doğruluk (fidelity) denir, çünkü uyum iyiliğini (goodness of fit) sözkonusu veri için ödüllendirir. İkinci terime ise fire denir, çünkü Xb 'nin *önsel* (a priori) olarak (teori ya da başka verisetleri ile yapılan tahmin sonuçları vs değerlendirildiğinde) makul olduğunu düşündüğümüz $X\beta^*$ değerlerinden sapmalarını cezalandırır. Yukarıdaki tahminci için normal denklemler şu şekilde ifade edilir:

$$X'(Y - X\tilde{\beta}) + \lambda X'X(\tilde{\beta} - \beta^*) = 0,$$

ve $\tilde{\beta}$ için çözüldüğünde şu elde edilir

$$\tilde{\beta} = (X'X(1 + \lambda))^{-1}(X'Y + \lambda X'X\beta^*) = \frac{\hat{\beta}}{1 + \lambda} + \frac{\lambda}{1 + \lambda}\beta^*$$

Dikkat ederseniz, $\lambda = 0$ 'a eşitlendiğinde OLS'in $\hat{\beta}$ 'sı elde edilir ve $\lambda \approx \infty$ olduğunda uzman tahmini β^* elde edilir.

λ 'nın seçimi sıkça uygulamacılara (practitioners) bırakılır. Tahmin amacına yönelik olarak, λ ortalama kare hatayı minimize edecek şekilde seçilebilir. Bu da *çapraz geçерleme* (cross-validation) denen bir yolla elde edilebilir.

3.5. GM'da Normallik Varsayımı Altında Sonlu Örneklem Çıkarılması. Çıkarılma amacıyla, OLS'nin varyansını tahmin etmemiz gerekir. $\sigma^2(X'X)^{-1}$ için yansız bir tahmini $s^2(X'X)^{-1}$ olarak oluşturabiliriz; burada

$$s^2 = \widehat{e}'\widehat{e}/(n - K) \text{ 'dır.}$$

$E_\theta[s^2|X] = \sigma^2$ 'in yansızlığı şuradan gelir

$$\begin{aligned} E_\theta[\widehat{e}'\widehat{e}|X] &= E_\theta[\varepsilon' M_X \varepsilon | X] = E_\theta[\text{tr}(M_X \varepsilon \varepsilon') | X] \\ &= \text{tr}(M_X E[\varepsilon \varepsilon' | X]) = \text{tr}(M_X \sigma^2 I) \\ &= \sigma^2 \text{tr}(I - P_X) = \sigma^2 (\text{tr}(I_n) - \text{tr}(P_X)) = \sigma^2 (\text{tr}(I_n) - \text{tr}(I_K)) = \sigma^2 (n - K), \end{aligned}$$

burada şunları kullandık: $\text{tr}(AB) = \text{tr}(BA)$, iz'in (trace) ve beklenti işlemcisinin doğrusallığı ve $\text{tr}(P_X) = \text{tr}((X'X)^{-1}X'X) = \text{tr}(I_K)$ olduğu.

Aynı zamanda önemli bir ek varsayımı da eklememiz gerekti:

$$\text{GM5. } \varepsilon|X \sim N(0, \sigma^2 I) \quad \text{Normallik}$$

Bu şekilde, Y 'nin X verildiğindeki koşullu dağılım modelimiz parametrik hale geldi ve koşullu dağılımın parametre vektörünü $\theta = (\beta, \sigma^2)$ 'a eksiltti (reduced).

Normallik varsayımı nasıl haklı çıkartılabilir? Bazı deneme yanılma yöntemleri tartışılabilir.

Teorem 3.2. *GM.1-GM.5 varsayımları altında şunlar doğrudur:*

1. $\hat{\beta}|X \sim N(\beta, \sigma^2(X'X)^{-1})$, $Z_j := (\hat{\beta}_j - \beta_j)/\sqrt{\sigma^2(X'X)^{-1}_{jj}} \sim N(0, 1)$.
2. $(n - K)s^2/\sigma^2 \sim \chi^2(n - K)$.
3. s^2 ve $\hat{\beta}$ bağımsızdırlar.
4. $t_j := (\hat{\beta}_j - \beta_j)/se(\hat{\beta}_j) \sim t(n - K) \approx N(0, 1)$, şunun için $se(\hat{\beta}_j) = \sqrt{s^2(X'X)^{-1}_{jj}}$; yaklaşıklık \approx ise $(n - K) \geq 30$ olduğunda doğrudur (accurate).

3.6. 3.2 Teoreminin ispatı. Şu olguları kullanacağız:

- (a) bir normal dağılımın doğrusal fonksiyonu bir normaldir, yani eğer $Z \sim N(0, \Omega)$ ise, o zaman $AZ \sim N(0, A\Omega A')$,
- (b) eğer iki normal vektör ilgisiz ise, o zaman ikisi bağımsızdırlar,
- (c) eğer $Z \sim N(0, I)$ ve Q simetrik ve denkgüçlü (idempotent) ise, o zaman $Z'QZ \sim \chi^2 \text{kerte}(Q)$ 'dır,

- (d) eğer bir standart normal değişken $N(0, 1)$ ve ki-kare (chi-square) değişken $\chi^2(J)$ bağımsız iseler, o zaman $t(J) = N(0, 1)/\sqrt{\chi^2(J)/J}$ bir J serbestlik dereceli (degrees of freedom) Student t değişkeni (Student's t) olarak adlandırılır.

Özellik (a)-(c)'nin ispatını ödev olarak gösteriniz.

Şimdi şu iddiaların herbirini ispatlayalım:

- (1) $\hat{e} = M_X \varepsilon$ ve $\hat{\beta} - \beta = (X'X)^{-1}X'\varepsilon$ sıfır ortalama ile birleşik olarak normaldirler, çünkü bir normal vektörün doğrusal fonksiyonu normaldir.
- (2) \hat{e} ve $\hat{\beta}$ ilgisizdirler, çünkü kovaryansları $\sigma^2(X'X)^{-1}X'M_X = 0$ 'a eşittir ve bu sebeple birleşik normallikten dolayı bağımsızdırlar. s^2 ise \hat{e} 'in bir fonksiyonudur, yani $\hat{\beta}$ 'ten bağımsızdır.
- (3)

$$(n - K)s^2/\sigma^2 = (\varepsilon/\sigma)'M_X(\varepsilon/\sigma) \sim \chi^2(\text{kerte}(M_X)) = \chi^2(n - K).$$

- (4) Özellikler 1-3 ile şunları gösterebiliriz

$$t_j = Z_j / \sqrt{(s^2/\sigma^2)} \sim N(0, 1) / \sqrt{\chi^2(n - K)/(n - K)} \sim t(n - K).$$

□

Özellik 4 önsav sınavı (hypothesis testing) yapmamızı ve güven aralıkları (confidence intervals) kurmamızı sağlar. Şu olaya (event) sahibiz

$$t_j \in [t_{\alpha/2}, t_{1-\alpha/2}] \text{ 'nin ihtimali } 1 - \alpha \text{ 'dır,}$$

burada t_α , bir $t(n - K)$ değişkeninin α -bölütünü ifade eder. Bu nedenle, β_j 'yi $1 - \alpha$ ihtimali ile kapsayan bir güven bölgesi (confidence region) şu şekilde ifade edilir

$$I_{1-\alpha} = [\hat{\beta}_j \pm t_{1-\alpha/2} se(\hat{\beta}_j)].$$

Bu da olay $\beta_j \in I_{1-\alpha}$ 'nın olay $t_j \in [t_{\alpha/2}, t_{1-\alpha/2}]$ 'a eşdeğer olmasından ortaya çıkar.

Ayrıca, şunu sınamak için

$$H_o : \beta_j = 0 \text{ karşı } H_a : \beta_j > 0$$

$t_j = (\hat{\beta}_j - 0)/se(\hat{\beta}_j) \geq t_{1-\alpha}$ 'in bir kritik değer olarak sağlandığını kontrol ediyoruz. Geleneksel uygulama, kritik değer $t_{1-\alpha}$ 'in öyle seçilmesidir ki, sıfır önsavını (null hypothesis) doğru iken hatalı şekilde reddetmenin ihtimali çok küçük bir değer olan α 'ya eşit olsun; burada α 'nın kanonik (canonical) seçimi 0.01, 0.05 veya 0.1'e

eşittir. Sıfır önsavı altında, t_j bir $t(n - K)$ dağılımı takip eder, $t_{1-\alpha}$ değerini de standart tablolardan bulabiliriz.

Şunu test etmek için

$$H_o : \beta_j = 0 \text{ karşı } H_a : \beta_j \neq 0$$

$|t_j| \geq t_{1-\alpha/2}$ olup olmadığına bakıyoruz. Kritik değer $t_{1-\alpha/2}$ ise hatalı ret ihtimali α olacak şekilde seçilir.

Sadece "reddet" veya "reddetme" sonuçlarını bildirmek yerine p-değerini (p-value) – sıfır önsavı altında t_j 'ye eşit ya da bundan büyük bir istatistiği görme ihtimalini, bildirmek de yaygın bir uygulamadır:

$$P_j = 1 - Pr[t(n - K) \leq t] \Big|_{t=t_j}$$

tek yanlı almasıklar (one sided alternatives) için, ve $|t_j|$

$$P_j = 1 - Pr[-t \leq t(n - K) \leq t] \Big|_{t=|t_j|}$$

ise iki yanlı almasıklar içindir. $Pr[t(n - K) \leq t]$ ihtimali, $t(n - K)$ 'nin dağılım fonksiyonudur, bu da Student dağılımı ile sıralanır (tabulated).

P-değerleri, önsav sınaması için t-istatistiklerini kullanmaya eşdeğer şekilde kullanılabilir. Gerçekten de, bir önsavı eğer $P_j \leq \alpha$ ise reddedebiliriz.

Örnek. Temin'in Roma Buğday Fiyatları. Temin, bir mesafe indirim modeli (distance discount model) tahmin etmiştir:

$$fiyat_i = \beta_1 + \beta_2 \cdot mesafe_i + \epsilon_i, \quad i = 1, \dots, 6$$

burada $fiyat_i$ Roma eyaletlerinde buğdayın fiyatı ve $mesafe_i$ ise i eyaletinin Roma'ya olan uzaklığıdır. Tahmin edilen model şudur

$$fiyat_i = \underset{(0.49)}{-1.09} - \underset{(0.0003)}{0.0012} \cdot mesafe_i + \hat{\epsilon}_i, \quad R^2 = 0.79,$$

standart hatalar parantez içinde gösterilmiştir. Sınama $\beta_2 = 0$ 'a karşı $\beta_2 < 0$ için kullanılan t istatistiği $t_2 = -3.9$ 'dur. Tek yanlı sınama için P-değeri $P_2 = P[t(4) < -3.9] = 0.008$ 'dir. β_2 için bir %90 güven bölgesi $[-0.0018, -0.0005]$ 'tir; bu da $[\hat{\beta}_2 \pm t_{0.95}(4) \cdot se(\hat{\beta}_2)] = [0.0012 \pm 2.13 \cdot 0.0003]$ olarak hesaplanır.

Teorem 3.3. *GM1-GM5 varsayımları altında, $\hat{\beta}$ en çok olabilirlik tahmincisi (maximum likelihood estimator) ve aynı zamanda β 'nin en küçük varyans yansız tahmincisidir.*

İspat. Bu ispat, $\hat{\beta}$ 'in varyansının yansız tahminciler için Cramer-Rao alt sınırını (Cramer-Rao lower bound) sağladığını doğrulayarak gösterilir. Bu durumda, y_i 'nin $y_i = y'$ 'deki x_i üzerine koşullu yoğunluğu şu şekildedir

$$f(y|x_i, \beta, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{1}{2\sigma^2}(y - x_i'\beta)^2\right\}.$$

Böylece, olabilirlik fonksiyonu şudur

$$L(b, \sigma^2) = \prod_{i=1}^n f(y_i|x_i, b, \sigma^2) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left\{-\frac{1}{2\sigma^2}(Y - Xb)'(Y - Xb)\right\}.$$

Burada OLS $\hat{\beta}$ 'nin β üzerinde olabilirlik fonksiyonunu en çokladığı kolayca görülebilir (bunu kontrol ediniz).

Burada, $\theta = (\beta, \sigma^2)$ 'in yansız tahmincilerinin varyansının (koşullu) Cramer-Rao alt sınırı şuna eşittir (sağlamasını yapınız)

$$\left[-E \left[\frac{\partial^2 \ln L}{\partial \theta \partial \theta'} \middle| X \right] \right]^{-1} = \begin{bmatrix} \sigma^2(X'X)^{-1} & 0 \\ 0 & 2\sigma^4/n \end{bmatrix}.$$

Buradan da en küçük karelerin alt sınırı sağladığı çıkarılır.

3.7. OLS'in Rakipleri ve Alternatifleri. Bölüm II. Hatalar normal dağılmadığı takdirde, OLS'in diğer tahmincilerle göre performansı ciddi ölçüde kötüleşebilir.

Örnek. Koenker and Bassett (1978) çalışması.

3.8. Dışlanmış Buluşsal Yöntemler (Omitted Heuristics): ε 'un normalliği nereden gelmektedir? Poincare: "Herkes Gauss'un hata yasasına (law of error) inanmaktadır; deneyciler bunun bir matematik teoremi olduğunu düşündükleri için, matematikçiler ise deneysel bir olgu olduğunu düşündükleri için."

Gauss (1809) en küçük karelerin en çok olabilirlik tahmini olduğu bir hata dağılımı oluşturmak için geriye dönük çalışmıştır. Bu nedenle, normal dağılıma bazen Gaussçu da (Gaussian) denmektedir.

Merkezi Limit Teoremi (MLT, Central Limit Theorem, CLT)"ispatı":

Ekonometride, Haavelmo, 1944'teki *Econometrica*'da yayımlanan "Probability Approach to Econometrics (Ekonometriye Olasılık Yaklaşımı)" makalesinde, bu

ispatın seçkin bir destekçisi olmuştur. MLT ispatında, her bir hata ε_i 'nin büyük sayıdaki küçük ve bağımsız basit (elementary) hatalar olan v_{ij} 'nin toplamı olduğu düşünülür, bu sebeple de bu hatalar merkezi limit teoremi ışığında yaklaşık olarak Gaussçu'dur.

Eğer basit hatalar olan v_{ij} , $j = 1, 2, \dots$ sıfır ortalamalı, özdeş ve bağımsız dağılımlı (i.i.d., identically and independently distributed) ise ve $E[v_{ij}^2] < \infty$ ise, o zaman *büyük N için*

$$\varepsilon_i = \sqrt{N} \left[\frac{\sum_{j=1}^N v_{ij}}{N} \right] \approx_d N(0, E v_{ij}^2),$$

bu MLT'den elde edilmektedir.

Ancak, eğer basit hatalar v_{ij} iid ve simetrik iseler ve $E[v_{ij}^2] = \infty$ ise, o zaman *büyük N için* (v_{ij} 'nin kuyruk (tail) hareketlerine getirilecek ek teknik kısıtlar ile)

$$\varepsilon_i = N^{1-\frac{1}{\alpha}} \left[\frac{\sum_{j=1}^N v_{ij}}{N} \right] \approx_d \text{Kararlı (Stable)'} \text{dır}$$

burada α en büyük sonlu beklemdir (finite moment): $\alpha = \sup\{p : E|v_{ij}|^p < \infty\}$. Bu da Khinchine ve Levy tarafından ispat edilen MLT'den gelmektedir. Kararlı dağılımlar aynı zamanda toplam-kararlı (sum-stable) ve *Pareto-Levy* dağılımları olarak da adlandırılırlar.

Simetrik kararlı dağılımların yoğunlukları yaklaşık olarak güç fonksiyonları (power functions) gibi hareket eden kalın kuyruklara (thick tails) sahiptirler; kuyruklarda $\alpha < 2$ ile $x \mapsto \text{sabit} \cdot |x|^{-\alpha}$ 'dır.

Başka bir ilginç ek gözlem: Eğer $\alpha > 1$ ise, örneklem ortalaması olan $\sum_{j=1}^N v_{ij}/N$ bir yakınsayan istatistiktir (converging statistic), eğer $\alpha < 1$ ise örneklem ortalaması olan $\sum_{j=1}^N v_{ij}/N$ bir ıraksayan istatistiktir (diverging statistic), bunun da farklılaşma ve farklılaşmama (diversification and non-diversification) için ilginç uygulamaları vardır. (Son husus için bkz. R. Ibragimov'un çalışmaları).

Referanslar: Embrechts et al. *Modelling Extremal Events (Uç Olayları Modelleme)*

3.9. Genel Doğrusal Kısıtlamalar ile Sınama ve Tahmin Etme. Şimdi de şu şekilde verilen bir doğrusal eşitlik kısıtlamasını sınımayı düşünelim

$$H_0 : R\beta = r, \quad \text{kerte}R = p.$$

burada R bir $p \times K$ matrisi ve r ise p -vektörüdür. Varsayım olarak R 'nin tam satır kertesinin olması (full row rank) basitçe artık kısıtlamaların (redundant restrictions) olmadığını ifade eder – yani diğer kısıtlamaların doğrusal kombinasyonu olarak yazılabilecek kısıtlamalar mevcut değildir. Alışık ise şudur

$$H_0 : R\beta \neq r.$$

Bu düzenleme birçok önsavı sınımamıza imkan sağlar. Örneğin,

$$R = [0, 1, 0, \dots, 0] \quad r = 0 \quad \text{şu kısıtlamayı oluştur } \beta_2 = 0$$

$$R = [1, 1, 0, \dots, 0] \quad r = 1 \quad \text{şu kısıtlamayı oluştur } \beta_1 + \beta_2 = 1$$

$$R = [\mathbf{0}_{p \times (K-p)} I_{p \times p}] \quad r = (0, 0, \dots)' \quad \text{şu kısıtlamayı oluştur } \beta_{K-p+1} = 0, \dots, \beta_K = 0.$$

H_0 'ı sınamak için, Wald istatistiğinin bir kritik değeri geçip geçmediğine bakıyoruz:

$$W := (R\hat{\beta} - r)'[\widehat{Var}(R\hat{\beta})]^{-1}(R\hat{\beta} - r) > c_\alpha,$$

burada kritik değer olan c_α sıfır önsavı doğru iken hatalı ret ihtimali α 'ya eşit olacak şekilde seçilmektedir. GM1-5 ile, şunu kabul edebiliriz

$$(3) \quad \widehat{Var}(R\hat{\beta}) = s^2 R(X'X)^{-1} R'.$$

Şunu çıkartabiliriz $W_0 = (R\hat{\beta} - r)'[\sigma^2 R(X'X)^{-1} R']^{-1}(R\hat{\beta} - r) = N(0, I_p)^2 \sim \chi^2(p)$ ve bu da $s^2/\sigma^2 \sim \chi^2(n-K)/(n-K)$ 'ı sağlayan s^2 'den bağımsızdır. Bu sebeple, şunu çıkartabiliriz

$$W/p = (W_0/p)/(s^2/\sigma^2) \sim \frac{\chi^2(p)/p}{\chi^2(n-K)/(n-K)} \sim F(p, n-K),$$

burada c_α , $F(p, n-K)$ çarpı p 'nin α -bölütü olarak alınabilir. Buradaki W/p istatistiğine F istatistiği (F-statistic) denir.

Hipotezi test etmenin diğer bir yolu mesafe fonksiyonu (distance function, DF) testidir (yarı-olabilirlik oranı sınaması, quasi likelihood ratio test) ve bu da ölçüt (criterion) fonksiyonunun kısıtsız (unrestricted) tahmini ve kısıtlı (restricted) tahmininden

elde edilen değerlerinin farkına bağlıdır:

$$Q_n(\hat{\beta}_R) - Q_n(\hat{\beta}),$$

bizim durumumuz için şunlar geçerlidir $Q_n(b) = (Y - X'b)'(Y - X'b)/n$, $\hat{\beta} = \arg \min_{b \in \mathbb{R}^K} Q_n(b)$ ve

$$\hat{\beta}_R = \arg \min_{b \in \mathbb{R}^K: Rb=r} Q_n(b)$$

Aşağıdaki eşdeğerlik, (3)'te belirtilen kurgu için de geçerli olmaktadır:

$$DF = n[Q_n(\hat{\beta}_R) - Q_n(\hat{\beta})]/s^2 = W,$$

yani, mesafe fonksiyonu testinin kullanılması Wald testi kullanılmasına denktir. Bu denklik daha genel olarak GM modeli dışında geçerli değildir.

Başka bir önemli test prensibi de LM test prensibidir; bu da Lagrange Çarpanının (Multiplier) yukarıda belirtilen kısıtlamalı optimizasyon problemi değeri üzerinden hesaplanır. Problem için Lagrange değeri şudur

$$\mathcal{L} = nQ_n(b)/2 + \lambda'(Rb - r).$$

Optimumu tanımlayan koşullar şunlardır

$$X'(Y - Xb) + R'\lambda = 0, Rb - r = 0$$

Bu denklemler çözüldüğünde şunu elde ederiz

$$\hat{\beta}_R = (X'X)^{-1}(X'Y + R'\hat{\lambda}) = \hat{\beta} + (X'X)^{-1}R'\hat{\lambda}$$

$b = \hat{\beta}_R$ değerini $Rb - r = 0$ kısıtına koyduğumuzda, $R(\hat{\beta} + (X'X)^{-1}R'\hat{\lambda}) - r = 0$ değeri elde edilir, ya da

$$\hat{\lambda} = -[R(X'X)^{-1}R']^{-1}(R\hat{\beta} - r).$$

İktisatta çarpan, bir kısıtın gölge fiyatı (shadow price) olarak adlandırılır. Sınama problemimizde, eğer kısıtın fiyatı çok yüksek ise, hipotezi reddederiz. Test istatistiği şu formu alır:

$$LM = \hat{\lambda}'[\widehat{Var}(\hat{\lambda})]^{-1}\hat{\lambda},$$

Bizim durumumuzda, $\widehat{Var}(R\hat{\beta}) = s^2R(X'X)^{-1}R'$ için, şu değeri kullanabiliriz

$$\widehat{Var}(\hat{\lambda}) = [R(X'X)^{-1}R']^{-1}\widehat{Var}(R\hat{\beta})[R'(X'X)^{-1}R]^{-1}$$

Bu kurgu bizim özel örneğimiz için şu eşdeğerliği de vermektedir

$$LM = W.$$

Bu eşitliğin doğrusal olmayan tahminciler için geçerli olmasının gerekmediğine dikkat ediniz (aslında genel olarak bu istatistikler için yanaşık (asymptotic) eşdeğerlik geçerlidir).

Yukarıda kısıtlanmalı tahmini de türetmiştik:

$$\hat{\beta}_R = \hat{\beta} - (X'X)^{-1}R'[R(X'X)^{-1}R']^{-1}(R\hat{\beta} - r).$$

Sıfır önsavı doğru olduğunda, şunu gösterebiliriz

$$E[\hat{\beta}_R|X] = \beta$$

ve

$$Var[\hat{\beta}_R|X] = FVar(\hat{\beta}|X)F', \quad F = (I - (X'X)^{-1}R'[R(X'X)^{-1}R']^{-1}R).$$

Matris anlamında, şunu göstermek zor değildir

$$Var[\hat{\beta}_R|X] \leq Var[\hat{\beta}|X]$$

ve dolayısıyla ROLS (restricted, kısıtlı) $\hat{\beta}_R$ yansızdır ve OLS'den daha etkindir. Bu eşitsizliğin sağlaması doğrudan yapılabilir; bu sonucu göstermenin başka bir yolu aşağıda verilmiştir. Bu GM teoremi ile çelişmekte midir? Hayır. Neden?

Ortaya çıkmaktadır ki, GM modelinde *kısıtlanmalı* parametre $\{\beta \in \mathbb{R}^K : R\beta = r\}$ ile, ROLS en küçük varyans yansız doğrusal tahmincidir. Benzer şekilde, GM normal modelinde *kısıtlanmalı* parametre $\{\beta \in \mathbb{R}^K : R\beta = r\}$ ile, ROLS aynı zamanda en küçük varyans yansız tahmincidir. Dikkat ederseniz, daha önceden kısıtlamasız parametre uzayı olan $\{\beta \in \mathbb{R}^K\}$ ile çalışmıştık.

Kısıtlanmış regresyon problemi kısıtlamasız bir regresyona dönüştürülebilir. Bu husus ilk olarak $\beta_1 + \beta_2 = 1$ kısıtlaması kullanılan bir örnekle gösterilebilir. Şunu yazınız

$$Y = X_1\beta_1 + X_2\beta_2 + \epsilon = X_1(\beta_1 + \beta_2 - 1) + X_2\beta_2 - X_1(\beta_2 - 1) + \epsilon = (X_2 - X_1)\beta_2 - X_1 + \epsilon$$

veya

$$Y - X_1 = (X_2 - X_1)\beta_2 + \epsilon,$$

Yeni modelin Gauss-Markov varsayımlarını sağladığını kolaylıkla kontrol etmek şu parametre uzayı ile mümkündür

$$\theta = (\beta_2, \sigma^2, F_{\epsilon|X}, F_X),$$

burada $\beta_2 \in \mathbb{R}$ kısıtlamasızdır. Yani, son ifadeye LS uygulanarak elde edilen $\hat{\beta}_{R2}$ etkin doğrusal tahmincidir (normallik varsayımında etkin tahminci). Benzer durum $\hat{\beta}_{R1} = 1 - \hat{\beta}_{R2}$ için de geçerlidir, çünkü bu $\hat{\beta}_{R2}$ 'nin doğrusal bir işlevselidir. Bu sebeple, ROLS $\hat{\beta}_R$ kısıtlamasız doğrusal en küçük kareler tahmincisi olan $\hat{\beta}_2$ 'den daha etkindir.

Bu fikir rahatlıkla genelleştirilebilir. Genel durumu bozmayacak şekilde, bağlaştıranların sıralamasını yeniden düzenleyebiliriz, şöyle ki

$$R = [R_1 \ R_2],$$

burada R_1 bir tam kerte p olan $p \times p$ matrisidir. $H_0 : R\beta = r$ 'yi uygulamak, $R_1\beta_1 + R_2\beta_2 = r$ veya $\beta_1 = R_1^{-1}(r - R_2\beta_2)$ 'ye eşdeğer olur, bu durumda da

$$Y = X_1\beta_1 + X_2\beta_2 + \epsilon \stackrel{H_0}{=} X_1(R_1^{-1}(r - R_2\beta_2)) + X_2\beta_2 + \epsilon,$$

bu da şunu gösterir

$$Y - X_1R_1^{-1}r = (X_2 - X_1R_1^{-1}R_2)\beta_2 + \epsilon \text{ dur.}$$

Bu da bize tekrar yeni bir bağımlı değişkenli ve yeni bir bağlaştıranlı model verir ve önceki GM çerçevesine uygun olur. Bu çerçevede $\hat{\beta}_{2R}$ tahmini ve aynı zamanda $\hat{\beta}_{1R} = R_1^{-1}(r - R_2\hat{\beta}_{2R})$ tahmini etkindir.

3.10. Sonlu Örneklemde Normallik Olmadan Çıkarsama. Sonlu-örneklemde Monte-Carlo (MC) yönteminin temel fikri aşağıdaki örnekle şu şekilde gösterilebilir.

Örnek 1. Varsayalım $Y = X\beta + \epsilon$, $E[\epsilon|X] = 0$, $E[\epsilon\epsilon'|X] = \sigma^2I$, $\epsilon = (\epsilon_1, \dots, \epsilon_n)'$ = σU olsun, burada

$$(4) \quad U = (U_1, \dots, U_n)|X, \ F_U \text{ kuralı ile iid'dir}$$

burada kullanılan F_U bilinmektedir. Örneğin, $F_U = t(3)$ alınırsa, birçok finansal getiri verisetlerinin özelliklerini $F_U = N(0, 1)$ 'den daha iyi sağlayacaktır.

Şimdi $H_0 : \beta_j = \beta_j^0$ 'a karşı $H_A : \beta_j > \beta_j^0$ 'yi sınadığımızı düşünelim. H_0 altında

$$(5) \quad t_j = \frac{\hat{\beta}_j - \beta_j^0}{\sqrt{s^2(X'X)^{-1}_{jj}}} \stackrel{H_0 \text{ ile}}{=} \frac{((X'X)^{-1}X'\epsilon)_j}{\sqrt{\frac{\epsilon'M_X\epsilon}{n-K}(X'X)^{-1}_{jj}}} = \frac{((X'X)^{-1}X'U)_j}{\sqrt{\frac{U'M_XU}{n-K}(X'X)^{-1}_{jj}}}$$

Dikkat ederseniz bu istatistik bilinmeyen parametre σ^2 'yi hoş bir şekilde sadeleştirmektedir.

Bu testin p-değeri Monte-Carlo ile hesaplanabilir. T-istatistiğinin H_0 altında üretilebilecek çekim (draw) değerlerini simule edelim:

$$(6) \quad \{t_{j,d}^*, d = 1, \dots, B\},$$

burada d çekim değerlerini sıralar, B toplam çekim sayısıdır ve büyük olması gerekmektedir. Her bir çekim değeri $t_{j,d}^*$ 'yi oluşturmak için, U 'nun (4)'a bağlı olarak çekimlerini oluşturalım ve bunları (5)'in sağ tarafına oturtalım. Sonrasında p-değeri şu şekilde tahmin edilebilir

$$(7) \quad P_j = \frac{1}{B} \sum_{d=1}^B 1\{t_{j,d}^* \geq t_j\},$$

burada t_j t-istatistiğinin görgül (empirical) değeridir. $H_0 : \beta_j = \beta_j^0$ 'a karşı $H_A : \beta_j \neq \beta_j^0$ 'ı sınamak için kullanılacak p-değeri şu şekilde tahmin edilebilir

$$(8) \quad P_j = \frac{1}{B} \sum_{d=1}^B 1\{|t_{j,d}^*| \geq |t_j|\}.$$

Güven bölgeleri ve testler için t-istatistiğine bağlı kritik değerler, (6) örnekleminin uygun bölütleri (quantile) elde edilerek oluşturulabilir.

Örnek 2. Şimdi, önceki örneği şu şekilde genelleştirelim: F_U bilinmeyen sorunlu (nuisance) parametre γ 'ya bağlı olsun ve bunun da gerçek değeri γ_0 'ın Γ bölgesinde olduğu bilinsin. Bağlılığı $F_U(\gamma)$ ile ifade edelim.

Örneğin, varsayalım $F_U(\gamma)$ "serbestlik derecesi" parametresi $\gamma \in \Gamma = [3, 30]$ olan bir t-dağılımı olsun; bu, çok ağır kuyruktan hafif kuyruğa kadar farklı kuyruk hareketi gösteren dağılımları yuvalama (nest) imkanı sağlar. Normal dağılım da $\gamma = 30$ ile yaklaşık olarak yuvalanır.

Sonrasında, her bir $\gamma \in \Gamma$ için p-değerini elde edelim ve bunu $P_j(\gamma)$ ile ifade edelim. Sonra şunu

$$\sup_{\gamma \in \Gamma} P_j(\gamma)$$

sinama amaçlı kullanalım. $\gamma_0 \in \Gamma$ olduğu için, bu değer gerçek P-değeri $P_j(\gamma_0)$ için geçerli bir üst sınırdır. Benzer şekilde, her bir $\gamma \in \Gamma$ için kritik değerler elde edilebilir ve *en az tercih edilen* kritik değer kullanılabilir. Sonuçta elde edilen güven bölgeleri eğer Γ büyük olursa oldukça tutucu (conservative) olabilir; ne var ki, son paragrafa bakınız.

Doğal olarak oluşan soru şudur: Neden gerçek parametre γ_0 'ın tahmini olan $\hat{\gamma}$ 'ı MC ile $\gamma = \hat{\gamma}$ 'a eşitleyerek kullanıp $P_j(\hat{\gamma})$ 'ı ve kritik değerleri elde etmeyelim? Bu yöntem parametrik *özçıkırım (bootstrap)* olarak bilinir. Özçıkırım, bir MC yöntemidir ve basitçe, p-değerlerini ve kritik değerleri tahmin edilen veri üretme süreci (data generating process) ile elde etmek için kullanılır. Özçıkırım yanaşık olarak geçerli çıkarsama sağlar, ancak özçıkırım her zaman geçerli sonlu örneklem çıkarsaması sağlamayabilir. Ancak, özçıkırım sonlu örneklemelerde sıklıkla yanaşık yaklaşımın sağladığından daha doğru (accurate) çıkarsama sağlar.

Yukarıdaki sonlu örneklem yaklaşımı veriye-bağlı Γ ile de kullanılabilir. Veriye bağlı sorunlu parametre kümesini $\hat{\Gamma}$ olarak ifade edelim. Eğer $\hat{\Gamma}$ kümesi γ_0 'ı $1 - \beta_n$ ihtimaliyle içerirse, ki burada $\beta_n \rightarrow 0$ 'dır, p-değerinin tahminini şu olacak şekilde ayarlayabiliriz

$$\sup_{\gamma \in \hat{\Gamma}} P_j(\gamma) + \beta_n.$$

Büyük örneklemelerde, şunu bekleyebiliriz

$$\sup_{\gamma \in \hat{\Gamma}} P_j(\gamma) + \beta_n \approx P_j(\gamma_0),$$

bu, $\hat{\Gamma}$ kümesi γ_0 'a yakınsadığında (converge) ve $\beta_n \rightarrow 0$ ise geçerlidir. Böylece, sonlu-örneklem yöntemi büyük örneklemelerde etkin olabilir, ancak sonlu örneklemelerde de geçerliliğini korur. Yanaşık yöntem veya özçıkırım'ın sonuncu ifadeyi sağlaması illa gerekmemektedir. Bu da yöntemleri ayırmaktadır. Ancak, başkalarının ifade edildiği gibi, sonlu-örneklem yöntemi "süslü (fancy) özçıkırım" olarak düşünülebilir.

Örnek 3. (Ödev) Temin'in (2005) makalesini düşünelim. Makale, Roma İmparatorluğu'nda eyaletin Roma'ya olan mesafesinin buğday fiyatları üzerindeki etkisini modellemektedir. Çalışmada sadece 6 tane gözlem vardır. Etkinin sıfıra eşit olduğu sıfır önsavına karşılık etkinin negatif olduğu almaşık önsavı test etmek için kullanılacak p-değerlerini hesaplayınız. Önce normal bozuklukların olduğu duruma bakınız (bu durum için simülasyon yapılmasına gerek yoktur), sonrasında ikinci

durum olarak bozuklukların 8 ve 16 "serbestlik derecelerine" sahip t-dağılımı takip ettikleri durumu analiz ediniz.

3.11. Ek: Kare Kayıp Altında Biraz Formal Karar Teorisi (Some Formal Decision Theory Under Squared Loss).

Amemiya (1985) tahmincilerin etkinliğini tartışmak için şu kuralcılıkları oluşturmaktadır.

1. $\hat{\beta}$ ve β^* bir skalar parametre β için skalar tahminciler olsun. Eğer $E_{\beta}(\hat{\beta} - \beta)^2 \leq E_{\beta}(\beta^* - \beta)^2, \forall \beta \in \mathcal{B}$ ise, $\hat{\beta} \succcurlyeq$ (en az onun kadar iyi) β^* 'dir.

“Daha iyi” nin tanımı karesel (quadratic) kayba bağlıdır.

2. Bazı $\beta \in \mathcal{B}$ için, eğer $\hat{\beta} \succcurlyeq \beta^*$ ve $E_{\beta}(\hat{\beta} - \beta)^2 < E_{\beta}(\beta^* - \beta)^2$ ise, $\hat{\beta}$ **daha iyidir** (daha etkindir, \succ) β^* 'dan,

3. $\hat{\beta}$ ve β^* vektör parametresi β için **vektör** tahminler olsun. Eğer tüm $c \in \mathbb{R}^k$, $c'\hat{\beta} \succcurlyeq c'\beta^*$ ($c'\beta$ 'yi tahmin etmek için) ise $\hat{\beta} \succcurlyeq \beta^*$ 'dir.

4. Eğer bazı $c \in \mathbb{R}^k$ için $c'\hat{\beta} \succ c'\beta^*$ ve tüm $c \in \mathbb{R}^k$ için $c'\hat{\beta} \succcurlyeq c'\beta^*$ ise, $\hat{\beta} \succ \beta^*$ 'dir.

Açıkça görülmelidir ki Tanım 3 ve Tanım 5 eşdeğerdir.

5. Eğer $A_{\beta} \equiv E_{\beta}(\hat{\beta} - \beta)(\hat{\beta} - \beta)'$ ise ve $B_{\beta} \equiv E_{\beta}(\beta^* - \beta)(\beta^* - \beta)'$ ise, $\hat{\beta} \succcurlyeq \beta^*$ 'dir; burada $A_{\beta} - B_{\beta} \forall \beta \in \mathcal{B}$ için yarı-negatif tanımlıdır veya matris kapsamında $A_{\beta} \leq B_{\beta}'$ 'dir.

6. $\hat{\beta}$ eğer bu sınıfta daha iyi tahminci yoksa, tahminci sınıfı içinde en iyidir.

4. BÜYÜK ÖRNEKLEMLERDE TAHMIN VE TEMEL ÇIKARSAMA

Bu kısım için iyi bir referans Newey'nin ders notlarıdır. Aşağıda, sadece temel sorunlara değinilecektir.

4.1. Temel Kurgu ve Bunların İfade Ettikleri. Büyük örneklemede geçerli çıkarsamaları önceki GM modelinin izin verdiğiinden çok daha genel koşullarda yapabiliriz.

Çalışabileceğimiz bir grup yeterli (sufficient) koşul şudur:

$$\mathbf{L1} \quad y_t = x_t' \beta + e_t, \quad t = 1, \dots, n$$

$$\mathbf{L2} \quad E e_t x_t = 0, \quad t = 1, \dots, n$$

$$\mathbf{L3} \quad X'X/n \rightarrow_p Q \text{ sonlu ve tam kerte}$$

$$\mathbf{L4} \quad X'e/\sqrt{n} \rightarrow_d N(0, \Omega), \text{ burada } \Omega \text{ sonludur ve yozlaşan değildir (non-degenerate).}$$

Tartışma:

1) L1 ve L2, β 'nin $E[y_t|x_t]$ koşullu beklenti fonksiyonuna en iyi doğrusal yaklaştırmayı tanımlayan parametre olduğunu ifade ederler. L1-L4 ile, OLS $\hat{\beta}$, β için tutarlı ve yanaşık (yaklaştırma manasında) olarak normal dağılan tahminci şeklinde ortaya çıkar.

2) Şu ayrıştırmayı yapabiliriz

$$e_t = a_t + \varepsilon_t,$$

burada $\varepsilon_t = y_t - E[y_t|x_t]$ ve

$$a_t = E[y_t|x_t] - x_t' \beta \text{ dir.}$$

Hata terimi bu sebeple şunların toplamıdır: y_t 'nin koşullu ortalamadan sapması olarak tanımlanan "alışıldık" (usual) bozukluk ε_t ve doğru fonksiyon $E[y_t|x_t]$ yerine doğrusal işlevsel biçim kullanılmasından oluşan hata olarak ortaya çıkan yaklaştırma (belirginleştirme) hatası a_t . Önceki GM çerçevesinde, yaklaştırma hatası olmadığını varsaymıştık. Şu anki çerçevede, buna "gücümüz yeter". Açıkça belirtebiliriz ki sadece gerçek koşullu ortalama fonksiyonuna bir yaklaşıklık tahmin ediyoruz ve açıkça hesaba katabiliriz ki yaklaşıklık hatası farklı yayılımın (heteroscedasticity) (neden?) tahmincimizin varyansını etkileyen önemli bir sebebidir.

3) L3 bir önceki özdeşleştirme (identification) koşulunun sadece bir örnekselidir (analog). Aynı zamanda, bağlaştıranların t çarpımının $\{x_t x_t', t = 1, \dots, n\}$ Büyük Sayılar Yasası'nı (BSY, Law of Large Numbers, LLN) sağlaması gerekmektedir; bu

şekilde onların üzerine bir kararlılık (stability) yüklemektedir. Bu koşul yönelimli bağıştıranlar (trending regressors) eklenerek gevşetilebilir (bakınız, örneğın, Newey'in notları veya Amemiya'nın "Advanced Econometrics" kitabı).

4) L4, $\{x_t e_t, t = 1, \dots, n\}$ dizisinin bir MLT'i sağlaması gerektiğini ifade eder. Bu koşul, daha önce hataların normal olması hakkında yaptığımız varsayımdan oldukça daha geneldir. Büyük örneklemlerde, bu koşul bizi daha önce normallik altında elde ettiğimiz tahmin ve çıkarsama sonuçlarının benzerlerine götürecektir.

Önerme 4.1. *L1-L4 ile, $\hat{\beta} \rightarrow_p \beta$.*

Örnekleme büyüklüğü arttıkça, $\hat{\beta}$ tahmini β 'ya yaklaşacaktır. Açıkçası, tutarlılık için, L4'ü daha az kısıtlayıcı olan $X'e/n \rightarrow_p 0$ gereksinimi ile değıştirebiliriz.

Önerme 4.2. *L1-L4 ile, $\sqrt{n}(\hat{\beta} - \beta) \rightarrow_d N(0, V)$, $V = Q^{-1}\Omega Q^{-1}$.*

Bu sonuç büyük örneklemlerde $\hat{\beta}$ 'nin β ortalaması ve V/n varyansı ile yaklaşık olarak normal dağıldığını önermektedir:

$$\hat{\beta} \approx_d N(\beta, V/n).$$

Önerme 4.3. *L1-L4 ile, varsayalım $\hat{V} \rightarrow V$ 'dir, bu durumda*

$$t_j := (\hat{\beta}_j - \beta_j)/s.e(\hat{\beta}_j) := (\hat{\beta}_j - \beta_j)/\sqrt{\hat{V}_{jj}/n} \rightarrow_d N(0, 1).$$

ve eğer R için tam kerte p ise, $R\beta = r$ ile

$$W = (R\hat{\beta} - r)'[R(\hat{V}/n)R']^{-1}(R\hat{\beta} - r) \rightarrow_d \chi^2(p).$$

Büyük örneklemlerde uygun şekilde oluşturulan t -istatistiğı ve W -istatistiğı yaklaşık olarak standart normal değışkenu ve p serbestlik dereceli ki-kare değışkenu ile dağılırlar; yani $t \approx_d N(0, 1)$ ve $W \approx_d \chi^2(p)$.

Bu sonuçların temel kullanımı sonlu-örneklem durumu ile tamamen aynıdır, istisna olarak artık hepsi yaklaşık olarak ifade edilmiştir. Örneğın, sıfır önsavı ile, bir t -istatistiğı $t_j \rightarrow_d N(0, 1)$ 'ı sağlar ve bu da şunu ifade eder

$$\lim_{n \rightarrow \infty} Pr[t_j < c] = Pr[N(0, 1) < c] = \Phi(c),$$

bu her bir c için geçerlidir, çünkü Φ süreklidir (continuous). Sonlu ve büyük örneklerde, sadece şu geçerlidir

$$Pr[t_j < c] \approx \Phi(c),$$

burada yaklaşımın kalitesi çeşitli durumlara bağlı olarak iyi ya da zayıf olabilir.

Dikkat ediniz: Kısıtlamalı en küçük kareler için, ki bu kısıtlamasız OLS'in bir doğrusal dönüşümüdür, yavaşık sonuçlar ve diğer test istatistikleri (örn. LM) yukarıda sunulan sonuçlardan kolayca çıkarılabilir.

Sonuçları ispat etmek için kullanacağımız temel araçlar Sürekli Eşleşme Teoremi (SET, Continuous Mapping Theorem, CMT) ve Slutsky Teoremi'dir. Bu sonuçlarda esas olan metrik uzaylar sonlu-boyutlu Euclid uzaylarıdır (Euclidian spaces).

Önsav 4.1 (SET). X bir rastsal eleman olsun ve $x \mapsto g(x)$ her bir $x \in D_0$ için sürekli olsun, burada bir olasılığı ile $X \in D_0$ 'dır. Varsayalım $X_n \rightarrow_d X$ olsun, bu durumda $g(X_n) \rightarrow_d g(X)$; eğer $X_n \rightarrow_p X$ ise, o zaman $g(X_n) \rightarrow_p g(X)$ 'dir.

Bu önsavın ispatı yukarıda belirtilen bir temsil teoreminin uygulamasından ve sonra da süreklilik hipotezinin kullanılmasından elde edilir. Takip eden önsav sürekli eşleşme teoreminin bir sonucudur (corollary).

Önsav 4.2 (Slutsky Önsavı). Matris $A_n \rightarrow_p A$ ve vektör $a_n \rightarrow_p a$ olduğunu varsayalım, burada matris A ve vektör a sabittir. Eğer $X_n \rightarrow_d X$ ise, o zaman $A_n X_n + a_n \rightarrow_d AX + a$ 'dir.

Önerme 1'in İspatı: Sırasıyla L4 and L3 koşulları şunu ifade eder

$$(2) \quad X'e/n \xrightarrow{p} 0, \quad X'X/n \xrightarrow{p} Q.$$

Sonrasında, Q 'nun tekilsizliği (nonsingularity) ile, bir matrisin tersinin matrisin elemanlarının her bir tekilsiz matriste sürekli fonksiyonu olmaları bilgisi ve Slutsky Önsavı ile şu elde edilir

$$\hat{\beta} = \beta + (X'X/n)^{-1} X'e/n \xrightarrow{p} \beta + Q^{-1} \cdot 0 = \beta.$$

Önerme 2'nin İspatı: L4 and L3 koşulları sırasıyla şunu ifade eder

$$(2) \quad X'e/\sqrt{n} \xrightarrow{d} N(0, \Omega), \quad X'X/n \xrightarrow{p} Q.$$

Slutsky Önsavı'ndan şu elde edilir

$$\sqrt{n}(\hat{\beta} - \beta) = (X'X/n)^{-1} X'e/\sqrt{n} \xrightarrow{d} Q^{-1} N(0, \Omega) = N(0, Q^{-1} \Omega Q^{-1}).$$

Önerme 3'ün İspatı: $\hat{V} \xrightarrow{p} V$, $V_{jj} > 0$ kullanılarak ve SET ile, $(V_{jj}/\hat{V}_{jj})^{1/2} \xrightarrow{p} 1$ 'dir. Slutsky Teorem'i kullanılarak şu çıkar

$$\left(\hat{\beta}_j - \beta_j\right) / [V_{jj}]^{1/2} = (V_{jj}/\hat{V}_{jj})^{1/2} \sqrt{n}(\hat{\beta}_j - \beta_j) / \sqrt{V_{jj}} \xrightarrow{d} 1 \cdot N(0, 1) = N(0, 1).$$

$\Sigma = RV R'$ olsun. Σ matrisi R 'nin p kertesine sahip olması ve V 'nin tekilsiz olması sebebiyle tekilsizdir, yani SET ile, $\hat{\Sigma}^{-1/2} \xrightarrow{p} \Sigma^{-1/2}$ 'dir. Ayrıca, Slutsky Önsavı ile $Z_n = \hat{\Sigma}^{-1/2} R \sqrt{n} (\hat{\beta} - \beta) \xrightarrow{d} Z = \Sigma^{-1/2} N(0, \Sigma) =_d N(0, I)$. Sonrasında SET ile, $W = Z_n' Z_n \rightarrow_d Z' Z =_d \chi^2(p)$ 'dir.

4.2. Bağımsız Örnekler. Burada iki modeli değerlendireceğiz:

IID Modeli: Varsayalım (a) $L1$ ve $L2$ sağlansın, (b) (y_t, x_t) vektörleri t üzerinde bağımsızdırlar ve özdeş dağılırlar, (c)

$$\Omega = \text{Var}[x_t e_t] = E[e_t^2 x_t x_t']$$

sonludur ve yozlaşmayandır (non-degenerate) (tam kerte), ve

$$Q = E[x_t x_t']$$

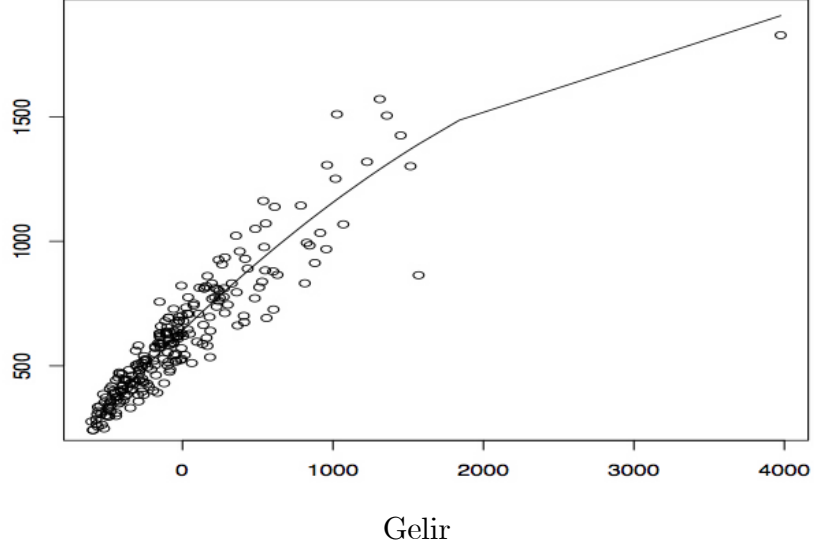
sonludur ve tam kertedir.

Bu koşulun y_t ve x_t arasındaki ilişkiyi hiçbir şekilde kısıtlamadığını vurgulamak gerekir; sadece (y_t, x_t) 'nin birleşik dağılım fonksiyonunun t 'ye bağımlı olmaması ve verinin t üzerinde bağımlılığının olmaması gerekmektedir.

Bu model, hata terimi $e_t = \varepsilon_t + a_t$ 'de farklı yayılımın iki kaynağına izin vermektedir— biri ε_t 'nin farklı yayılımı ve diğeri de yaklaşıklı hatası $a_t = E[y|x_t] - x_t' \beta$ 'nin farklı yayılımıdır. Farklı yayılımdan kastımız $E[e_t^2|x_t]$ 'nin x_t 'ye bağlı olmasıdır.

Örnek: Daha önce konuşulan Engel eğrisi örneğini hatırlayalım, ki örnekte ε_t açıkça farklı yayımlı idi. Bu sebeple, e_t de farklı yayımlıdır. İktisattaki birçok regresyon modeli farklı yayılım bozukluğuna sahiptir.

Gıda Harcaması



ŞEKİL 4

Örnek: Ücret nüfus sayımı verisinde basit işlevsel biçimler için $a_t \neq 0$ olduğunu görmüştük. Bu sebeple, $a_t \neq 0$ olduğu için e_t farklı yayımlı olmalıdır.

Teorem 4.1. *IID modelinin koşulları $L1-L4$ 'ün yukarıda tanımlanan Ω ve Q ile sağlandığını belirtmektedir. Bu sebeple, Önerme 1-3'ün sonuçları da sağlanmaktadır.*

İspat: Bu ispat Khinchine BSY ve çok değişkenli Lindeberg-Levy MLT'den elde edilmektedir.

V 'nin varyansının tutarlı bir tahmincisi (farklı yayılım dirençli tahminci (heteroscedasticity robust estimator)) şu şekilde ifade edilir:

$$\hat{V} = \hat{Q}^{-1}\hat{\Omega}\hat{Q}^{-1}, \quad \hat{\Omega} = E_n[e_t^2 x_t x_t'], \quad \hat{Q} = X'X/n.$$

Teorem 4.2. *IID modelinin koşulları ve ek varsayımlar (örn. x_t 'nin bağımlı dördüncü beklemleri (bounded fourth moments)) $\hat{\Omega} \rightarrow_p \Omega$ ve $\hat{Q} \rightarrow_p Q$ olduğunu ifade eder, bu şekilde $\hat{V} \rightarrow_p V$ 'dir.*

İspat: $\hat{Q} \rightarrow_p Q$ 'nin tutarlılığı Khinchine BSY'den çıkmaktadır ve $\hat{\Omega} \rightarrow_p \Omega$ 'ın tutarlılığı şu şekilde gösterilebilir. Gösterimi basitleştirmek için skalar duruma

bakalım. Şunu elde etmiş durumdayız

$$\hat{e}_t^2 = e_t^2 - 2(\hat{\beta} - \beta)'x_t e_t + (\hat{\beta} - \beta)^2 x_t^2.$$

İki tarafı da x_t^2 ile çarpalım ve t üzerinden ortalama alarak şunu elde edelim

$$E_n[\hat{e}_t^2 x_t^2] = E_n[e_t^2 x_t^2] - 2(\hat{\beta} - \beta)E_n[e_t x_t^3] + (\hat{\beta} - \beta)^2 E_n[x_t^4].$$

Sonrasında, $E_n[e_t^2 x_t^2] \rightarrow_p E[e_t^2 x_t^2]$, $E_n[x_t^4] \rightarrow_p E[x_t^4]$ ve Khinchine BSY ile $E_n[e_t x_t^3] \rightarrow_p E[e_t x_t^3]$ 'dir, çünkü $E[x_t^4]$ varsayımdan dolayı sonludur ve $E[e_t x_t^3]$ şundan dolayı sonludur

$$|E[e_t x_t x_t^2]|^2 \leq E[e_t^2 x_t^2]E[x_t^4]$$

bu da Cauchy-Schwartz eşitsizliğinden ve $E[e_t^2 x_t^2]$ ve $E[x_t^4]$ 'nin varsayılan sonluluğundan kaynaklanır. $\hat{\beta}$ 'nin tutarlılığından, yukarıdaki özelliklerden ve SET'den tutarlılığı elde ederiz. \square .

Eşit Yayımlı (Homoscedastic) IID Modeli: *IID modelinin (a)-(c) koşullarına ek olarak, varsayalım $E[e_t|x_t] = 0$ ve $E[e_t^2|x_t] = \sigma^2$ olsun, bu durumda $Var[e_t^2|x_t] = \sigma^2$ 'dir, bu da şu şekilde sadeleşir*

$$\Omega = \Omega_0 := \sigma^2 E[x_t x_t'].$$

Bu modelde yaklaşıklık hatası yoktur, yani $e_t = \varepsilon_t$ 'dir ve farklı yayılım yoktur. Bu model normalliğin dayatılmadığı bir Gauss-Markov modelidir.

Teorem 4.3. *Eşit yayımlı iid modelinde, $L1$ - $L4$ şunlar ile sağlanır: $\Omega_0 = \sigma^2 E[x_t x_t']$ ve $Q = E[x_t x_t']$, yani $V = V_0 := \sigma^2 Q^{-1}$.*

İspat. Bu, bir önceki sonuç kullanılarak doğrudan çıkartılır.

Eşit yayımlı iid modeli için, V 'nin varyansının tutarlı bir tahmincisi (dirençli olmayan (non-robust)) şu şekilde ifade edilir:

$$\hat{V}_0 = s^2 (X'X/n)^{-1}$$

Teorem 4.4. *Eş yayımlı iid modelinin koşulları $\hat{V}_0 \rightarrow_p V_0$ olduğunu belirtir.*

İspat. Q^{-1} matrisi $(X'X/n)^{-1}$ tarafından $X'X/n \xrightarrow{p} Q$ ile tutarlı olarak tahmin edilir, bu da BSY ve SET ile sağlanır. $s^2 = \hat{\varepsilon}'\hat{\varepsilon}/(n - K)$ olduğunu gösterebiliriz,

burada $\hat{\varepsilon} = y - X\hat{\beta}$ 'dir. $X'\varepsilon/n \xrightarrow{p} 0$ ve $X'X/n \xrightarrow{p} Q$ kullanılarak şu elde edilir

$$(4) \quad s^2 = \begin{bmatrix} \frac{n}{n-K} & \frac{\varepsilon'\varepsilon}{n} + & 2(\beta - \hat{\beta})' & (\frac{X'\varepsilon}{n}) + & (\beta - \hat{\beta})' & (\frac{X'X}{n}) & (\beta - \hat{\beta}) \end{bmatrix} \xrightarrow{(SET)} \sigma^2,$$

$$\begin{array}{cccccc} \downarrow & \downarrow p & \downarrow p & \downarrow p & \downarrow p & \downarrow p \\ 1 & \sigma^2 & 0 & 0 & 0 & Q \\ & \text{(BSY)} & \text{(OLS)} & \text{(BSY)} & \text{(OLS)} & \text{(BSY)} \end{array}$$

burada (OLS) ile OLS tahmincisinin tutarlılığı kastedilmektedir. Yani, SET ile, $s^2(X'X/n)^{-1} \xrightarrow{p} \sigma^2 Q^{-1}$. \square .

Yorum: Farklı yayımlılık ile $V \neq V_0$ 'dır, ve V_0 ile karşılaştırıldığında V daha büyük ya da küçük olabilir. Bunun sağlandığına dikkat ediniz. Uygulamada, V sıklıkla V_0 'dan büyüktür.

4.3. Bağımlı Örneklemeler. Birçok makroekonomik ve finansal durumlarda zaman serileri serisel olarak bağımlıdır (serially dependent) (yani t üzerinden bağımlıdır). Bunun bazı örneklerini düşünebilirsiniz.

Bağımlılık birçok şekilde modellenilebilir. Bazı parametrik modelleri GLS ile bağlantılı olarak MIT'de verilen 14.382 dersinde görebilirsiniz. Burada temel parametrik olmayan (non-parametric) modelleri tanıtacağız.

Takip eden kısımlarda veriyi şu şekilde düşünebiliriz: $z_t = (y_t, x_t)'$, $t = 1, \dots, n$ sonsuz bir akım olan $\{z_t\} = \{z_t, t = \pm 1, \pm 2, \dots\}$ 'nin bir alt kümesidir.

Eğer her bir $k \geq 0$ için (z_t, \dots, z_{t+k}) dağılımı (z_1, \dots, z_{1+k}) dağılımına eşitse, yani t 'ye bağlı değilse, $\{z_t\}$ *durağan (stationary)* olarak tanımlanır. Bunun sonucu olarak, ortalama ve kovaryans durağanlığı da elde edilir: $E[z_t] = E[z_1]$ her bir t için ve $E[z_t z_{t+k}'] = E[z_1 z_{1+k}']$ her bir t için.

(a) Karıştırma (Mixing). Karıştırma, dönemsel bağımlılığı ifade ederken kullanılan oldukça matematiksel bir düşünce tarzıdır.

$\{h_t\}$ durağan bir süreç olsun. $k \geq 1$ için şunu tanımlayın

$$\alpha_k = \sup_{A, B} \left| P(A \cap B) - P(A)P(B) \right|$$

burada $\sup A \in \sigma(h_0, h_{-1}, h_{-2}, \dots)$ ve $B \in \sigma(h_k, h_{k+1}, \dots)$ durumları üzerinden hesaplanır. Basit olarak, bu sigma-alanlarını (sigma fields) parantezler içindeki değişkenler tarafından oluşturulmuş bilgi (information) olarak düşünebiliriz. Eğer $k \rightarrow \infty$ iken $\alpha_k \rightarrow 0$ ise, $\{h_t\}$ *kuvvetli karıştırma (strongly mixing)* veya *alfa*

karıştırma (alpha mixing) olarak adlandırılır. Eğer veri iid ise, her bir k için $\alpha_k = 0$ 'dır.

Karıştırma koşulu, birbirinden k zaman birimi ayrılmış veri bloklarının bağımlılığının k arttığında dağılacığını (azalacağını) belirtir. Bir çok parametrik modelin bazı düzenlilik (regularity) koşulları altında karıştırma olduğu gösterilmiştir.

Önsav 4.3 (Bir Ergodik BSY). *Eğer $\{h_t\}$ sonlu bir ortalama $E[h_t]$ ile durağan kuvvetli karıştırma ise, o zaman $E_n[h_t] \rightarrow_p E[h_t]$ 'dir.*

Dikkat ediniz. Bu BSY'nın daha genel bir uyarlaması Birkhoff ergodik teoremi olarak adlandırılır.⁸

Önsav 4.4 (Gordin'in MLT'i). *Eğer $\{h_t\}$ bir kuvvetli durağan karıştırma süreci ise ve $E[h_t] = 0$, $\sum_{k=1}^{\infty} \alpha_k^{\delta/(2+\delta)} < \infty$, $E\|h_t\|^{2+\delta} < \infty$ ise, o zaman*

$$\sum_{t=1}^n h_t/\sqrt{n} \rightarrow_d N(0, \Omega),$$

burada

$$\Omega = \lim_n Var\left(\sum_{t=1}^n h_t/\sqrt{n}\right) = \lim_n \left(\Omega_0 + \sum_{k=1}^{n-1} \frac{n-k}{n} (\Omega_k + \Omega'_k)\right) = \Omega_0 + \sum_{k=1}^{\infty} (\Omega_k + \Omega'_k) < \infty,$$

burada $\Omega_0 = Eh_1h_1'$ ve $\Omega_k = Eh_1h_{1+k}'$ 'dir.

Burada karıştırmanın derecesindeki (rate) kısıt ve bekleme koşulu kovaryansın sonlu miktar olan Ω 'a toplandığını belirtir; aşağıdaki nota da bakınız. Bu gerçekleşirse, seriye zayıf-bağımlı (weakly-dependent) denir.

Kovaryans toplanabilirliğini ima eden bir yeterli koşul şu şekilde düşünülebilir: $k \rightarrow \infty$ 'a giderken, şuna sahip olmak yeterlidir

$$c > 1 \text{ için } \Omega_k/k^{-c} \rightarrow 0.$$

Kovaryanslar $1/k$ 'dan daha hızlı azalmalıdır. Bu gerçekleşmezse, serilerin uzun hafızaya (long memory) sahip oldukları söylenir. Finansta kullanılan yüksek frekanslı veri genelde uzun hafızaya sahip olarak düşünülür; bunun sebebi kovaryansın çok yavaş şekilde azalmasıdır. Uzun hafızaya yönelik yavaş kuramı burada anlatılan yavaş kuramından yeteri kadar farklıdır [Referans olarak bakınız: H. Koul.]

⁸Bakınız, örn. <http://mathworld.wolfram.com/BirkhoffsErgodicTheorem.html>

Dikkat ediniz. Gordin'in teoreminde, kovaryans toplanabilirliği Ibragimov'un durağan seriler için karıştırma eşitsizliğinden çıkarılır (burada skalarlar için ifade edilmiştir):

$$|\Omega_k| = |Eh_t h_{t+k}| \leq \alpha_k^{1-\gamma} [E[h_t]^p]^{1/p} [E[h_t]^q]^{1/q}, \quad \frac{1}{p} + \frac{1}{q} = \gamma \in (0, 1).$$

$p = 2 + \delta$ olarak belirlendiğinde, kovaryans toplanabilirliği $\sum_{k=-\infty}^{\infty} |\Omega_k| < \infty$ karıştırma katsayıları üzerine konulan kısıtlamadan çıkarılır.

Teorem 4.5. *Varsayalım $\{(y_t, x_t)\}$ durağandır, kuvvetli karıştırıcıdır ve $L1$ ve $L2$ geçerlidir. Varsayalım $\{\tilde{h}_t\} = \{x_t x_t'\}$ sonlu ortalamaya sahiptir, bu taktirde $L3$ koşulu $Q = E[x_t x_t']$ ile geçerlidir. Varsayalım $\{h_t\} = \{x_t e_t\}$ Gordin'in koşullarına sığlasın, bu taktirde $L4$ yukarıda belirtilen Ω formu ile geçerlidir.*

İspat: Sonuç önceki iki teoremden ve karıştırmanın tanımından elde edilir.

Yukarıdaki formül, Ω için şu tahminciyi önerir:

$$\hat{\Omega} = \hat{\Omega}_0 + \sum_{k=1}^{L-1} \frac{L-k}{L} (\hat{\Omega}_k + \hat{\Omega}'_k),$$

burada $\hat{\Omega}_0 = E_n[h_t h_t'] = \frac{1}{n} \sum_{t=1}^n h_t h_t'$ ve $\hat{\Omega}_k = E_n[h_t h_{t+k}'] = \frac{1}{n-k} \sum_{t=1}^{n-k} h_t h_{t+k}'$ 'dir. Belli teknik koşullar altında ve budama gecikmesi (truncation lag) üzerinde koşullar ile, mesela $L/n \rightarrow 0$ ve $L \rightarrow \infty$ gibi, tahmincinin tutarlı olduğu gösterilmiştir.

$\hat{V} = \hat{Q}^{-1} \hat{\Omega} \hat{Q}^{-1}$ tahmincisi yukarıda belirtilen formun $\hat{\Omega}$ hali ile sıklıkla HAC tahmincisi ("farklı yayımlı ve kendisiyle ilişkilimli tutarlı tahminci," heteroscedasticity and autocorrelation consistent, HAC) olarak adlandırılmıştır. Bazı düzenlilik (regularity) koşulları ile, tahminci gerçekten de tutarlıdır. Bu koşullar ve ispat için, bakınız Newey and West çalışması.

(b) Martingale fark dizileri (MFD, Martingale difference sequences, MDS). Veri zamansal olarak bağımlı olabilir ama kovaryanslar Ω_k yine de sıfır olabilirler ("hepsi geçiren" (all-pass) serileri); sonuçta yukarıdaki Ω sadeleşerek Ω_0 olur. MFD bunun gerçekleşmesinin bir örneğidir. MFD akılcı beklentiler (rational expectations) ile (Hansen and Singleton'a bakınız) ve aynı zamanda etkin piyasa hipotezi (efficient market hypothesis) ile (Fama'ya bakınız) bağlantılı olarak da önemlidirler. Referans olarak detaylı bir ders kitabı olan H. White, Asymptotic Theory for Econometricians'a bakınız.

z_t 'nin bir elemanı h_t olsun ve $I_t = \sigma(z_t, z_{t-1}, \dots)$ olsun. $\{h_t\}$ süreci, eğer $E[h_t|I_{t-1}] = h_{t-1}$ ise, I_{t-1} süzmesine (filtration) bağlı olarak bir martingale'dir. $\{h_t\}$ süreci, eğer $E[h_t|I_{t-1}] = 0$ ise, I_{t-1} süzmesine bağlı olarak bir martingale fark dizisidir (difference sequence).

Örnek. Hall'ın karesel fayda ve akılcı beklentiler ile oluşturduğu temsili tüketici modelinde şuna sahibiz

$$E[y_t|I_{t-1}] = 0,$$

burada $y_t = c_t - c_{t-1}$ 'dir ve I_t ise t döneminde mevcut olan bilgidir. Yani, akılcı ve en iyileme (optimization) hedefleyen bir tüketici bugünkü tüketim miktarını takip eden dönemlerdeki tüketimin ortalamasında değişiklik olmayacağı beklentisi ile oluşturur.

Önsav 4.5 (Billingsley'in Martingale MLT'i). $\{h_t\}$ durağan ve kuvvetli karıştırmalı bir martingale fark dizisi olsun ve $\Omega = E[h_t h_t']$ sonlu olsun. Bu durumda $\sqrt{n}E_n[h_t] \rightarrow_d N(0, \Omega)$ 'dır.

Bu teorem sezgisel (intuitive) olarak manalıdır, çünkü h_t 'ler özdeş dağılımlıdır ve ilgisizdirler. Aslında, $k \geq 1$ için $E[h_t h_{t-k}'] = E[E[h_t h_{t-k}'|I_{t-k}]] = E[E[h_t|I_{t-k}]h_{t-k}'] = 0$ 'dır, çünkü $E[h_t|I_{t-k}] = E[E[h_t|I_{t-1}]|I_{t-k}] = 0$ 'dır. McLeish bu teoremin güzel bir genelleştirmesini yapmıştır.

Teorem 4.6. Varsayalım $\{(y_t, x_t)\}$ serisi durağan ve kuvvetli karıştırma olsun. Ayrıca, varsayalım (a) $e_t = y_t - x_t' \beta$, $I_{t-1} = \sigma((e_{t-1}, x_{t-1})', (e_{t-2}, x_{t-2})', \dots)$ süzmesine bağlı bir martingale fark dizisi olsun, yani $E[e_t|I_{t-1}] = 0$, (b) $\Omega = E[e_t^2 x_t x_t']$ sonlu olsun, ve (c) $Q = E[x_t x_t']$ sonlu ve tam kerte olsun. Bu durumda L1-L4 yukarıda tanımlanan Ω ve Q ile geçerlidir. Bu sebeple, Öneriler 1-3'ün sonuçları da geçerlidir.

İspat. Şunu biliyoruz: $E[e_t|x_t] = E[E[e_t|I_{t-1}]|x_t] = 0$, bu da L1 ve L2'yi ima eder. Şunu Ergodik BSY ile biliyoruz: $E_n[x_t x_t'] \rightarrow_p Q = E[x_t x_t']$, bu da L3'ü sağlar. $\Omega = E[e_t^2 x_t x_t']$ ile Martingale MLT'den $\sqrt{n}E_n[e_t x_t] \rightarrow_d N(0, \Omega)$ olduğunu biliyoruz, bu da L4'ü sağlar. \square

Açıklama 4.1. IID durumunda olduğu gibi Ω ve Q için aynı tahminciyi kullanabiliriz

$$\widehat{\Omega} = E_n[\hat{e}_t^2 x_t x_t'], \quad \widehat{Q} = E_n[x_t x_t'].$$

$\widehat{\Omega}$ 'in tutarlılığı daha önce olduğu gibi $E[\|x_t\|^4] < \infty$ varsayımı ile sağlanır. İspat da daha öncesi ile aynıdır, sadece iid veri için her zamanki BSY yerine Ergodik BSY kullanılmalıdır. \widehat{Q} 'in tutarlılığı da ergodik BSY'den elde edilir.

Örnek. Hall'ın örneğinde,

$$E[y_t - x_t'\beta_0|x_t] = 0,$$

bu $\beta_0 = 0$ ve bilgi setine $t - 1$ zamanında dahil olan ve herhangi bir değişkeni temsil eden x_t için geçerlidir. Hall'ın hipotezi ile,

$$\sqrt{n}(\widehat{\beta} - \beta_0) \rightarrow_d N(0, V), \quad V = Q^{-1}\Omega Q^{-1}, \quad \beta_0 = 0$$

burada $\Omega = E[y_t^2 x_t x_t']$ ve $Q = E x_t x_t'$ 'dir. Sonrasında, Hall'ın hipotezi Wald istatistiği kullanılarak sımanabilir:

$$W = \sqrt{n}(\widehat{\beta} - \beta_0)' \widehat{V}^{-1} \sqrt{n}(\widehat{\beta} - \beta_0),$$

burada, yukarıda tanımlanan $\widehat{\Omega}$ ve \widehat{Q} için $\widehat{V} = \widehat{Q}^{-1} \widehat{\Omega} \widehat{Q}^{-1}$ 'dir.